

ESTIMACIÓN DE PROFUNDIDAD DE DEFECTOS MECÁNICOS INTERNOS EN
LÁMINAS DE CFRP BASADA EN UN CLASIFICADOR TIPO RNA Y EL
ALGORITMO DE CONTRASTE CTFF

MARÍA CAMILA BRAVO ORDÓÑEZ

UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA ACADÉMICO DE INGENIERÍA ELECTRÓNICA
CALI, FEBRERO DE 2017

ESTIMACIÓN DE PROFUNDIDAD DE DEFECTOS MECÁNICOS INTERNOS EN
LÁMINAS DE CFRP BASADA EN UN CLASIFICADOR TIPO RNA Y EL
ALGORITMO DE CONTRASTE CTFF

MARÍA CAMILA BRAVO ORDÓÑEZ

DIRECTORES:
ANDRÉS DAVID RESTREPO GIRÓN, Ph.D.
WILFREDO ALFONSO MORALES, Ph.D.

UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA ACADÉMICO DE INGENIERÍA ELECTRÓNICA
CALI, FEBRERO DE 2017

Agradecimientos

A Dios por darme la fortaleza y paciencia para afrontar todas las pruebas encontradas en el transcurso de mi carrera.

A mi madre, Lola Ordoñez, por su constante apoyo, cariño y confianza, quien resaltó siempre mis capacidades para culminar con éxito este proceso.

A Karol, Juliana, Pablo y José Luis, por su apoyo incondicional. Me enseñaron que no existen obstáculos.

A mis abuelos, quienes dejaron unas bases y valores que permiten dejar huellas en el camino, acompañadas de éxito y reconocimiento.

A mi familia, de generación en generación ha prevalecido el apoyo mutuo: pilares de mi formación.

A mis Directores, Andrés David Restrepo y Wilfredo Alfonso Morales, por su dedicación y enseñanzas las cuales me permitieron desarrollar habilidades para llevar a cabo este Trabajo.

A la Universidad del Valle, a la Escuela de Ingeniería Eléctrica y Electrónica y a sus excelentes profesores quienes aportaron valiosas enseñanzas a mi formación como Ingeniera y como persona.

En general, a todas las personas de quienes aprendí a maravillarme de las cosas simples de la naturaleza. Su compañía ha sido un garante en el éxito de hoy.

Resumen

Las diferentes técnicas de ensayo no destructivo (END) en la industria, como método de análisis para todo tipo de materiales y procesos, están en constante evolución por la manera de examinar, sin alterar de forma permanente las propiedades físicas, químicas o mecánicas de los cuerpos, identificando de forma temprana los defectos y discontinuidades a partir de la relación de la temperatura con los procesos de transferencia de calor del objeto. Las técnicas END permiten estimar y controlar estos elementos, de manera rápida, sencilla y sin contacto. Sin embargo, los métodos de contraste requieren de modelos de propagación o compensación térmica, para facilitar la separación de los defectos mecánicos internos encontrados en materiales compuestos tipo CFRP (Láminas de plástico reforzado con fibra de carbono). Este trabajo implementa una red neuronal artificial como clasificador con el fin de discriminar diferentes profundidades en defectos mecánicos. Los resultados obtenidos muestran la capacidad en procesar la información térmica usando el contraste de compensación térmica de fondo mediante filtrado (CTFF) para obtener diversas profundidades en el material compuesto, con un porcentaje de acierto del 97.2%, para la secuencia de imágenes a 157Hz, y de 98.9% para la secuencia de imágenes a 90Hz. Además, se realizó una comparación con el contraste absoluto modificado (CAD-m) usando la misma metodología donde se obtuvo un 96.5% de acierto a 157Hz y 96.4% a 90Hz. Los resultados demuestran que CTFF es una técnica superior a CAD-m para la detección y caracterización de defectos.

Tabla de Contenido

1.	Introducción	1
1.1	Antecedentes.....	1
1.2	Problema de Investigación.....	3
1.3	Objetivos.....	4
1.3.1	Objetivo General	4
1.3.2	Objetivos Específicos.....	4
1.4	Organización de la Tesis	4
2.	Marco Teórico.....	6
2.1	Materiales Compuestos.....	6
2.1.1	Características de los materiales compuestos	6
2.1.2	Láminas de Plástico Reforzadas con Fibra de Carbono	7
2.2	Termografía	8
2.3	Técnicas de Termografía Activa	9
2.3.1	Termografía Pulsada	9
2.3.2	Termografía por Escalón Térmico	10
2.3.3	Vibrotermografía	10
2.4	Técnicas de Mejoramiento de Contraste Térmico	11
2.4.1	CAD - Contraste Absoluto Diferencial.....	12
2.4.2	CAD-m - Contraste Absoluto Diferencial- modificado	12
2.4.3	CTFF - Compensación Térmica de Fondo mediante Filtrado	14
2.5	Redes Neuronales.....	18
2.5.1	Red Perceptron Multicapa (MLP).....	19
2.5.2	Modelo Funcional para Problemas de Clasificación	20
2.5.2.1	Arquitectura <i>feedforward</i> de clasificación con enfoque probabilístico	21
2.6	Resumen.....	22
3.	Metodología.....	24
3.1	Descripción del Sistema para la Extracción de Características	24
3.1.1	Extracción de Características.....	25

3.1.2	Patrones de Entrenamiento	27
3.2	Arquitectura de la Red Neuronal Artificial	28
3.3	Validación del Desempeño de la Red	30
3.3.1	Protocolo de Pruebas para la validación de la estimación de profundidad de defectos en una lamina CFRP	33
3.4	Resumen	34
4.	Análisis y Resultados	35
4.1	Análisis comparativo	50
4.1.1	Validación con Láminas Diferentes	57
4.2	Resumen	63
5.	Conclusiones y Trabajos Futuros	64
5.1	Conclusiones	64
5.2	Trabajos Futuros	65
6.	Referencias	67

Índice de Figuras

Figura 2.1 Fibra de Carbono	7
Figura 2.2 Configuración típica de termografía activa	8
Figura 2.3 Esquema de montaje de un experimento de termografía activa pulsada	10
Figura 2.4 Esquema de montaje de un experimento de termografía activa por escalón térmico.....	10
Figura 2.5 Esquema de montaje de un experimento de vibrotermografía	11
Figura 2.6 Aplicación de contraste CAD-m	14
Figura 2.7 Ejemplo de máscara modificada para el filtro mediana diezmado	16
Figura 2.8 Ejemplo de la expansión de los bordes de un termograma	17
Figura 2.9 Comparación entre un termograma original, su perfil de calentamiento de fondo estimado y su versión contrastada.....	18
Figura 2.10 Red Neuronal Artificial, Perceptron Multicapa.....	20
Figura 2.11 Red Neuronal Artificial, Multicapa Perceptron con varias salidas	20
Figura 2.12 Modelo de Red para problemas de clasificación	22
Figura 3.1 Interfaz gráfica TermolR	23
Figura 3.2 A) Secuencia original en el termograma 10. B) Secuencia con contraste CTFF en el termograma 10. C) Secuencia con contraste CAD-m en el termograma 10.	24
Figura 3.3 Esquema de downsampling	24
Figura 3.4 Señal original y señal con downsampling	24
Figura 3.5 Configuración para la extracción de características para cada pixel ..	26

Figura 3.6 Señal original (izquierda). Señal con ruido gaussiano (derecha).	27
Figura 3.7 Conjunto de entrenamiento organizado para la capa de entrada	28
Figura 3.8 Plantilla real de defectos 157Hz(Izquierda), Plantilla real de defectos 90Hz(derecha)	30
Figura 3.9 Matriz de confusión	30
Figura 3.10 Resumen estadístico de Matriz de confusión.	31
Figura 3.11 Matriz de confusión con Técnicas estadísticas	31
Figura 4.1 Muestras original del Banco de secuencias de 157Hz	34
Figura 4.2 Muestras original del Banco de secuencias de 90Hz.	34
Figura 4.3 Muestras CTFF del Banco de secuencias de 157Hz.	35
Figura 4.4 Muestras CTFF del Banco de secuencias de 90Hz.	35
Figura 4.5 Muestras CAD-m del Banco de secuencias de 157Hz.	35
Figura 4.6 Muestras CAD-m del Banco de secuencias de 90Hz.	36
Figura 4.7 Resultados de los entrenamientos de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 157Hz con contraste CTFF(Izquierda), Errores mínimos (Derecha).	37
Figura 4.8 Resultados de los entrenamientos de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 90Hz con contraste CTFF(Izquierda), Errores mínimos (Derecha).	37
Figura 4.9 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CTFF(Izquierda), Errores mínimos (Derecha).	38

Figura 4.10 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 90Hz con contraste CTFF(Izquierda), Errores mínimos (Derecha).....	38
Figura 4.11 Diagrama de Caja	39
Figura 4.12 Diagrama de caja de los errores de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 157Hz con contraste CTFF.....	40
Figura 4.13 Diagrama de caja de los errores de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 90Hz con contraste CTFF.....	40
Figura 4.14 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CTFF	40
Figura 4.15 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 90Hz con contraste CTFF..	41
Figura 4.16 Matriz de confusión con 5,6,19,25,27,29 neuronas de la Red MLP (entropía cruzada y softmax) para el banco de secuencias de 157Hz con contraste CTFF	42
Figura 4.17 Matriz de confusión con 5,6,7,8,14,27 neuronas de la Red MLP (entropía cruzada y softmax) para el banco de secuencias de 90Hz con contraste CTFF.....	43
Figura 4.18 Matriz de confusión con 7,9,11,16,26,30 neuronas de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CTFF.	44
Figura 4.19 Matriz de confusión con 4, 5, 7, 10 neuronas de la Red MLP (MSE) para el banco de secuencias de 90hz con contraste CTFF	45
Figura 4.20 Laminas resultantes izquierda 157Hz- derecha90Hz	47

Figura 4.21 Errores en la estimación de profundidad de la lámina con CTFF a) Errores externos a las profundidades 157Hz b) Errores internos en las profundidades 157Hz c) Errores externos a las profundidades 90Hz d) Errores internos en las profundidades 90Hz.....	48
Figura 4.22 Matriz de confusión 157Hz con CTFF	48
Figura 4.23 Matriz de confusión 90Hz con CTFF.....	48
Figura 4.24 Esquemático láminas CFRP007 (izquierda), CFRP008 (derecha) con intercesiones de teflón: a) vista frontal. b) vista lateral	49
Figura 4.25 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CAD-m(Izquierda), Errores mínimos (Derecha).....	50
Figura 4.26 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 90Hz con contraste CAD-m(Izquierda), Errores mínimos (Derecha).....	50
Figura 4.27 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CAD-m.....	51
Figura 4.28 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CAD-m.....	51
Figura 4.29 Láminas resultantes con CAD-m, izquierda 157Hz, derecha 90Hz ...	53
Figura 4.30 Errores en la estimación de profundidad de la lámina con CAD-m a) Errores externos a las profundidades 157Hz b) Errores internos en las profundidades 157Hz c) Errores externos a las profundidades 90Hz d) Errores internos en las profundidades 90Hz.....	53
Figura 4.31 Matriz de confusión 157Hz con CAD-m	54
Figura 4.32 Matriz de confusión 90Hz con CAD-m	54

Figura 4.33 Clasificación de defectos de 15mm organizados de manera ascendente respecto a la profundidad55

Figura 4.34 Lámina Obtenida (CFRP007) con CTFF57

Figura 4.35 Lámina Obtenida (CFRP008) con CTFF58

Figura 4.36 Lámina Obtenida (CFRP007) con CAD-m60

Figura 4.37 Lámina Obtenida (CFRP008) con CAD-m61

Índice de Tablas

Tabla 3.1 Resumen de la Matriz de confusión	31
Tabla 3.2 Asignación de colores para las diferentes profundidades	32
Tabla 4.1 Resultado de filtrados 1 y 2 para seleccionar la mejor arquitectura	41
Tabla 4.2 Mejores arquitecturas con CTFF	46
Tabla 4.3 Resultados del filtrado 1 y 2 para la selección de la mejor arquitectura para CAD-m	52
Tabla 4.4 Mejor arquitectura para experimentos con CAD-m	52
Tabla 4.5 Porcentaje de pixeles mal clasificados	54
Tabla 4.6 Redes que se utilizaron para generar la lámina Resultante de CFRP007 y CFRP008	56

1. Introducción

1.1 Antecedentes

La termografía infrarroja es un método de inspección rápido con técnicas de ensayo no destructivo y sin contacto, que es usado para analizar zonas con el propósito de localizar defectos por debajo de la superficie del material, haciendo una estimación cuantitativa de su profundidad, tamaño y grosor (Vavilov, 2004). La detección de defectos es un problema que se ha estudiado durante varios años desarrollando diversos modelos, como el propuesto por (Obbadi & Belattar, 2005), quienes implementaron el método de elementos finitos para detectar los defectos con los perfiles de temperatura. Los autores comprobaron la eficiencia del algoritmo en una lámina simulada. Finalmente concluyen que es una técnica con resultados exitosos que debe tener en cuenta la posición y el grosor de la delaminación en el material isotrópico. Sin embargo, los resultados en simulación no consideran factores que afectan en la realidad. Un estudio realizado por (Boras & Svaic, 2003) propuso un modelo numérico 3D no estacionario de conducción de calor que se basa en el método numérico con un volumen de control ajustable. Este estudio buscaba detectar la geometría y posición del defecto en un cilindro de acero con aire en su interior; sin embargo, consideraron que los resultados con una cámara-IR y un computador de mayor potencia podrían mejorarse.

Otros métodos han hecho uso de técnicas de inteligencia artificial, en particular de las redes neuronales artificiales. Un ejemplo de esto es el método propuesto por (Heriansyah & Abu, 2007) quienes utilizaron la termografía pasiva y una red Perceptron Multicapa (MLP) para estimar y caracterizar la profundidad de un defecto. Ellos consideraron como parámetros de entrada para la red MLP: temperatura máxima y mediana del área defectuosa y la temperatura en la zona sana, obteniendo un porcentaje de acierto del 98% en la estimación de profundidad de un defecto en una lámina y demostrando que las redes neuronales son un método eficiente para la detección de defectos; sin embargo, se cree que estos

resultados podrían variar al presentarse más de un defecto, debido a que la red neuronal podría confundirse al elegir entre una clase u otra. Para esclarecer la incertidumbre acerca de la capacidad de clasificación de la red, (Benítez H. , 2008) presenta la técnica de contraste absoluto modificado para la detección y caracterización de defectos en láminas CFRP (Láminas de plástico reforzado con fibra de carbono) por medio de termografía activa. El autor utilizó las Redes Neuronales MLP y RBF (Redes de Base Radial) para la detección y estimación de defectos utilizando como parámetros de entrada perfiles térmicos, encontrando que las peores detecciones, ejecutadas en dos tipos de láminas, con diferentes defectos a diferentes profundidades, son del 29% para la red MLP y de 71.25% para la red RBF (Benítez H. , 2008).

Con el análisis de los estudios presentados con técnicas de redes neuronales se puede observar que son métodos capaces de realizar una clasificación en una superficie que contenga diferentes tipos y profundidades de defectos, pero para esto es necesario que las características entre una clase y otra tengan las mayores diferencias posibles, las cuales dependen de la aplicación de los diferentes tipos de contrastes térmicos que se ejecuten al banco de secuencias obtenido por medio de la cámara IR. Recientemente, (Restrepo, 2013) presentó tres técnicas de contraste térmico: Compensación Térmica de Fondo mediante Filtrado (CTFF), Compensación Térmica de Fondo mediante Reconstrucción (CTFR) y Contraste Térmico por Diferencias Finitas (CTDF), las cuales fueron propuestas para darle solución al problema de detección y caracterización de defectos mediante procesamiento espacio-temporal de secuencias de imágenes infrarrojas. Entre las técnicas presentadas se destaca el método de Compensación Térmica de Fondo mediante Filtrado (CTFF), siendo una técnica que presenta buenos resultados como método de contraste térmico, al destacar las zonas defectuosas de manera satisfactoria.

1.2 Problema de Investigación

La detección de defectos con técnicas termográficas ha cobrado un marcado interés, dado que corresponde a una metodología de evaluación no destructiva, de no contacto y remota. No obstante, no sólo es importante la detección de estas fallas sino también su caracterización; es decir, la estimación de uno o más parámetros como la profundidad, que diferencien un defecto de otro. Por otro lado, se han venido aplicando estrategias de Inteligencia Artificial así como estadísticas desde la década de los años 90 (Darabi, 2000) como herramientas para la detección de estos defectos; desafortunadamente para algunos casos, las máquinas de aprendizaje no han arrojado resultados muy convincentes en cuanto a la estimación de profundidad. El problema podría estar asociado al conjunto de características usado para dicha detección. Nuevos mecanismos de detección como la compensación térmica de fondo mediante filtrado, CTFF, propuesta por (Restrepo, 2013), han sido planteados recientemente para mejorar el contraste térmico de los compuestos como las láminas de plástico reforzado con fibras de carbono (CFRP).

Con este nuevo método de extracción de información, se formula la siguiente pregunta de investigación: ¿Es posible mejorar los resultados de estimación de profundidad de defectos en láminas de plástico Reforzado con Fibra de Carbono (CFRP), usando Redes Neuronales Artificiales (RNA) y tomando la información de contraste entregada por el algoritmo de Compensación Térmica de Fondo mediante Filtrado (CTFF) que ha demostrado un mejor desempeño que otros métodos previos similares?

1.3 Objetivos

1.3.1 Objetivo General

Construir y analizar el desempeño de un sistema informático de estimación de profundidad de defectos mecánicos internos en láminas de CFRP, basado en una red neuronal artificial aplicada a una secuencia de imágenes IR contrastadas por Compensación Térmica de Fondo mediante Filtrado (CTFF).

1.3.2 Objetivos Específicos

- Revisar los elementos conceptuales relevantes de las RNA usados en la estimación de profundidad de defectos de laminación mediante inspección termográfica.
- Seleccionar las características más discriminantes de las imágenes de contraste CTFF que permitan la estimación de profundidad de defectos internos en placas de CFRP.
- Implementar un sistema basado en una RNA y en la información de contraste CTFF para la estimación de profundidad de defectos internos.
- Validar el desempeño del sistema de estimación de profundidad propuesto.
- Realizar un estudio comparativo con respecto a un trabajo típico de referencia.

1.4 Organización de la Tesis

En este trabajo se presentan las contribuciones al avance de la detección y clasificación de defectos a partir del contraste por Compensación Térmica de Fondo mediante Filtrado (CTFF) usando Redes Neuronales Artificiales (RNA).

El capítulo 1 presenta las investigaciones que se han desarrollado en el transcurso de los años para la detección y caracterización de defectos en láminas, dándole paso al nuevo problema de investigación, definiendo los objetivos que se cumplirán con el desarrollo del estudio. El capítulo 2 describe brevemente los métodos y elementos que se utilizarán para darle solución al problema, con el

propósito de contextualizar al lector antes de llegar al capítulo 3, donde se propone una metodología para la detección de profundidades en láminas CFRP con el contraste CTFF. El capítulo 4 se valida la metodología propuesta, expone los resultados con los que se realizó el análisis, define los algoritmos propuestos para el entrenamiento de las redes, donde finalmente se determina la mejor arquitectura para este tipo de problemas. Adicionalmente, se presenta un análisis comparativo con los resultados obtenidos en (Benítez H. , 2008). Por último, el capítulo 5 presenta las conclusiones más relevantes encontradas en la ejecución del estudio.

2. Marco Teórico

2.1 Materiales Compuestos

Los materiales compuestos surgen de la necesidad de tener una combinación de dos o más elementos que aprovechen las mejores características de sus materiales individuales constitutivos, con el fin de obtener cualidades estructurales no encontradas en materiales cerámicos, plásticos o metales por sí solos. *Los materiales compuestos son combinaciones macroscópicas de dos o más materiales diferentes que poseen una interface discreta y reconocible que los separa. Debido a ello, son heterogéneos (sus propiedades no son las mismas en todo su volumen). Si bien algunos materiales compuestos son naturales (como la madera o el hueso), la gran mayoría de los materiales compuestos utilizados en la actualidad son diseñados y “fabricados” por el hombre* (Stupenengo, 2011). Las propiedades de los materiales compuestos son definidas según la industria y la aplicación para la cual se necesita; por ejemplo, para la industria aeroespacial es necesario la construcción de materiales rígidos, ligeros, resistentes al impacto, la corrosión y al desgaste.

2.1.1 Características de los materiales compuestos

De los materiales compuestos se resaltan dos componentes: La **matriz** y el **refuerzo** manipulados para la fabricación de elementos estructurales.

La Matriz: Es la etapa permanente en la que el refuerzo queda embebido. Tiene como funciones principales: definir las propiedades físicas y químicas, transferir las cargas al refuerzo, preservar el material brindándole cohesión, y permite definir las características del material compuesto. Las principales propiedades de la matriz, en el material, son: mantener las fibras en la posición correcta, transportar las cargas a las fibras fuertes, y evitar la propagación de grietas en las fibras a lo largo del compuesto. Generalmente, es la encargada del control principal de las propiedades eléctricas y el comportamiento químico (Stupenengo, 2011).

El Refuerzo Es el elemento que se adiciona a la matriz para asignar al material compuesto alguna propiedad que la matriz no posee. Generalmente es un componente utilizado para aumentar la resistencia y rigidez; pero, también se utiliza para mejorar el comportamiento a altas temperaturas. Este es un elemento que puede ser adicionado en forma de partículas o fibras; resulta más efectivo en pequeñas dimensiones para garantizar la homogeneidad en su distribución.

2.1.2 Láminas de Plástico Reforzadas con Fibra de Carbono

Es un material compuesto, de propiedades excepcionales que tiene un costo relativamente elevado. A partir del 2007, aumentó su demanda en el área de la industria aeroespacial y automovilística, entre otras, por su rigidez, resistencia a la corrosión, propiedades de amortiguación, alta resistencia al impacto, expansión térmica exactamente modificable y su preservación de forma ante cambios de temperatura (Ingenieros, 2008).

Este es un material que consiste en un polímero (duroplásticos, termoplásticos) empleado como matriz en el cual se introducen fibras de carbono de diámetro pequeño, como se puede observar en la figura 2.1, lo que permite construir un material liviano, con relación al acero. Por esta razón, se ha convertido en uno de los materiales más importantes para la aeronáutica, pues su incorporación en la fabricación de aviones reduce en una disminución del consumo de combustible. Efecto que favorece la rentabilidad y la ecología.



Figura 2.1 Fibra de Carbono (Stupenengo, 2011)

2.2 Termografía

La termografía es una técnica implementada para la detección de temperaturas sin tener un contacto físico con las estructuras que se desee analizar. Utiliza como aparato de medición la cámara termográfica que capta la radiación infrarroja que se encuentre en su línea de vista. Esta es la medida para realizar el cálculo de la temperatura del objeto. Se ha clasificado la termografía en dos esquemas: Termografía pasiva y Termografía activa (AG & Auer, 2012) (Restrepo, 2013)

Termografía Pasiva. Se refiere a la termografía que no necesita de un impulso de calentamiento, o enfriamiento externo para inducir un flujo de calor en el cuerpo; solamente, es necesario una diferencia mínima de la temperatura de referencia del cuerpo inspeccionado, para capturar en tiempo real un comportamiento inusual del objeto desde una determinada distancia, por medio de un sistema de medición como la cámara infrarroja (Idurre & Borja, 2005).

Termografía Activa. Se denomina termografía activa aquélla que requiere de una fuente de calor, como se muestra en la figura 2.2, lo que produce un flujo de calor interno en el objeto estudiado (Idurre & Borja, 2005). Si la estructura estudiada presenta una no homogeneidad o defecto afectaría el flujo calorífico, produciendo lo que se denomina contraste térmico, el cual puede ser captado por una cámara infrarroja (Restrepo, 2013)




Figura 2.2 Configuración típica de termografía activa (Restrepo, 2013)

Ventajas de la termografía

- Facilidad para la medición de temperatura en objetos portables y de difícil acceso.

- Disminución de costos de manipulación y mantenimiento por la precisión de la localización de anomalías en tiempo real.
- Tiempo de respuesta reducido.
- Confiabilidad de las mediciones, por su exactitud y alta repetibilidad.
- Seguridad, sin contacto físico en la medición.
- Versatilidad en sus aplicaciones.

Desventajas

- Dependencia de resultados a las condiciones ambientales.
- Dificultad para lograr un calor uniforme en la plataforma u objeto a analizar.
- Línea de vista entre la cámara infrarroja y el objeto a analizar.

2.3 Técnicas de Termografía Activa

En los ensayos no destructivos de la termografía existen varias modalidades que son definidas por la manera en que se obtienen y son procesados los datos. Entre ellas están: Termografía Pulsada, Termografía por Escalón Térmico y Vibrotermografía, entre otras.

2.3.1 Termografía Pulsada

La termografía pulsada es una de las técnicas más frecuentes para la estimulación térmica de ensayos no destructivos de termografía, pues se trata de un método rápido, en el que se aplica un pulso corto de estimulación térmica, en la escala de milisegundos para materiales conductores y en segundos para materiales de baja conductividad térmica. En la termografía pulsada se registra la evolución de temperatura durante el enfriamiento de la pieza analizada (Figura 2.3). Por esta razón, es comúnmente usada en la inspección de componentes estructurales de aviones, como el control de calidad de soldadura por puntos, delaminaciones, grietas o corrosión, entre otras (Restrepo, 2013) (Idurre & Borja, 2005)




Figura 2.3 Esquema de montaje de un experimento de termografía activa pulsada (Restrepo, 2013)

2.3.2 Termografía por Escalón Térmico

La termografía por escalón térmico es una técnica que emplea un escalón de calor en vez de un pulso, y en la que se monitorea la temperatura durante y después del calentamiento. Por este motivo, en esta modalidad, no se necesita de fuentes de calor tan potentes como en la termografía pulsada, permitiendo la inspección de materiales de baja conductividad. (Figura 2.4). Este es un método que tiene diferentes aplicaciones como la especificación del grosor de capas de recubrimiento y evaluación de estructuras hechas con materiales compuestos (Benítez, Loaiza, & Caicedo, 2011) (Restrepo, 2013).




Figura 2.4 Esquema de montaje de un experimento de termografía activa por escalón térmico (Restrepo, 2013)

2.3.3 Vibrotermografía

La vibrotermografía es una técnica de ensayo no destructivo, que emite calor a partir de las vibraciones mecánicas entre 0 a 25 KHz aplicadas sobre el cuerpo que se desea analizar (Restrepo, 2013). El método de adquisición de las señales a través de esta técnica se presenta en la Figura 2.5.




Figura 2.5 Esquema de montaje de un experimento de vibrotermografía (Restrepo, 2013)

2.4 Técnicas de Mejoramiento de Contraste Térmico

El contraste térmico se define como la diferencia de temperatura entre dos áreas distintas. Esta propiedad es utilizada para la detección de defectos térmicamente no conductores tales como grietas, delaminaciones, sin comprometer la integridad física del objeto en observación. (Maldague., 2001), (A, D, J, & A, 2005), (Krapez, 1994)

En el ensayo termográfico no destructivo (ETND) el mejoramiento del contraste térmico se aplica con el propósito de optimizar la calidad de la imagen para visualizar los defectos, determinando sus características: Profundidad, grosor y tamaño en materiales compuestos.

Alrededor del mundo se han definido varios tipos de técnicas de mejoramiento de contraste, algunas basadas en modelos de propagación del calor, como el Contraste Absoluto Diferencial (CAD); otras, en el procesado temporal de los valores de temperatura de los pixeles de imagen, como en el Contraste Normalizado (CN); y otras, en transformaciones matemáticas como el Análisis en Componentes Principales (ACP) o el análisis Wavelet. Al interior del grupo PSI se han propuesto las siguientes técnicas de mejoramiento: El CAD modificado (CAD-m) y la Compensación Térmica de Fondo mediante Filtrado (CTFF) usando la termografía pulsada.

2.4.1 CAD - Contraste Absoluto Diferencial

El método de contraste absoluto diferencial, está basado en el prototipo unidimensional de transmisión de calor sobre una superficie de una placa semi-infinita de material sólido, sin imperfecciones, excitada mediante un pulso de Dirac, definido matemáticamente por la ecuación (2.1). Ecuación que se utiliza para estimar los valores de temperatura que tendría el material sin defectos, los cuales se restan de los valores reales registrados con la cámara IR. Por consiguiente las anomalías apreciables en las áreas defectuosas causarían un incremento de contraste térmico en la imagen, lo que permite detectar las imperfecciones de las láminas. (Restrepo, 2013) (Benitez, y otros, 2007)

$$T(t) = \frac{E}{e\sqrt{\pi t}} \quad (2.1)$$

En donde e corresponde a la efusividad térmica del material y E la energía térmica absorbida.

2.4.2 CAD-m - Contraste Absoluto Diferencial- modificado

Aunque el contraste diferencial obtiene resultados positivos sin requerir de la selección de un área sana, las muestras estudiadas deben ser relativamente gruesas y el pulso de calor se debe aproximar a un impulso de Dirac. Sin embargo, tal como lo presenta (Benitez, y otros, 2007), cuando las placas del material son delgadas *“ocurrirá un fenómeno de reflexión del frente térmico cuando llegue a la cara opuesta del objeto (cara no irradiada) que hace que el comportamiento de la temperatura, posterior a la reflexión, no coincida bien con lo predicho por el CAD”*; por consiguiente, esto influye en la caracterización de los defectos más profundos. Por otro lado, en algunas circunstancias en las que debe aplicarse un pulso de calor exponencial o cuadrado de un ancho suficiente para realizar una aproximación al impulso de Dirac $\delta(t)$ (a diferencia de cuando se trabaja con materiales de baja conductividad térmica) el periodo de duración del pulso de calor se convierte en un parámetro decisivo. Esta misma condición se presenta en materiales de alta conductividad térmica de pequeño espesor.

El CAD-modificado utiliza la teoría de cuádrupolos térmicos y emplea la transformada de Laplace de las ecuaciones diferenciales espacio-temporales del modelo dimensional de Laplace, para la transmisión térmica, siendo un método de menor complejidad, que supera las dos limitaciones del CAD. Así, sin contrarrestar el efecto de la duración del pulso, se extrae el CAD-m como se indica en la ecuación (2.2)

$$\Delta T(t)_{CAD-m} = T(t) - \frac{L^{-1} \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \Big|_t}{L^{-1} \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \Big|_{t'}} T(t') \quad (2.2)$$

En donde α es la difusividad térmica del material, h es el grosor de la placa, y s es la variable compleja de Laplace. Por consiguiente, para la nivelación del efecto del ancho de un pulso cuadrado de calor se obtiene la siguiente ecuación (2.3)

$$\Delta T(t)_{CAD-m} = T(t) - \frac{L^{-1} \left\{ \frac{1}{s} [1 - e^{-(tf)s}] \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \right\} \Big|_t}{L^{-1} \left\{ \frac{1}{s} [1 - e^{-(tf)s}] \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \right\} \Big|_{t'}} T(t') \quad (2.3)$$

En la figura 2.6 se puede observar la aplicación del contraste CAD-m a una lámina de CFRP con varios defectos a diferentes profundidades. Al lado izquierdo se presenta la imagen original de la cámara IR sin la aplicación del contraste CAD-m, mientras que a la derecha se presenta la nueva imagen después de la aplicación del filtro CAD-m. (Restrepo, 2013) (Benítez H. , 2008).




Figura 2.6 Contraste CAD-m. Imagen original (izquierda), Aplicación contraste CAD-m (derecha).

2.4.3 CTFF - Compensación Térmica de Fondo mediante Filtrado

Este método de contraste térmico propone una técnica que consiste en extraer de manera automática el fondo de la imagen en las áreas que se considera que no existirán defectos. En la observación de los termogramas adquiridos por una inspección de termografía IR activa se considera que el fondo está compuesto por la superficie sana del material, lo que permite determinar que en el mismo fondo se encuentra la información sobre el calentamiento no uniforme. Esta información corresponde a una frecuencia espacial baja, por lo que se plantea la ejecución de un filtro pasa-baja selectivo para separar la componente del calentamiento de fondo, con la ventaja de que ya no es necesario tener una definición inicial de los parámetros del material.

Teniendo en cuenta lo mencionado anteriormente, para esta técnica se propone el uso de un filtro mediana con el propósito de extraer el perfil de calentamiento de fondo. Para esto, es indispensable definir los posibles defectos que forman los detalles más relevantes que se deben suprimir de la imagen original.

A continuación se indica la metodología para implementar esta técnica:

- I. El primer paso consiste en extraer de una secuencia termográfica completa todas las imágenes adquiridas después que la excitación de calor se haya prolongado sobre la superficie del material. Luego se resta con una de las imágenes frías capturadas antes del pulso de calor, con el propósito de optimizar preliminarmente el contraste y disminuir los patrones de ruido de

la cámara IR. Si se presentan pixeles defectuosos de producción, se deben reparar en las imágenes como paso anticipado, y se debe tener en cuenta el filtrado de la secuencia para disminuir el ruido aleatorio presente en las imágenes. Si es necesario realizar un cálculo posterior con la imagen de referencia, esta debería ser la imagen inicial de la secuencia resultante.

- II. Como segundo paso se tiene la implementación de la máscara para el filtro mediana, la cual debe cumplir con el requisito fundamental de cubrir una zona que corresponde a una gran parte de la imagen, para filtrar el perfil de calentamiento no uniforme, suprimiendo los contrastes abruptos ocasionados por posibles defectos. No obstante, una dimensión importante puede deformar el propio perfil de fondo e incluso puede prolongar de manera exagerada el tiempo de ejecución.

Como opción para evitar la distorsión del perfil de fondo con la elección manual de la dimensión de la máscara de filtro mediana, se realiza el siguiente procedimiento en el cual se emplea *una máscara de lado M_0 igual a una fracción de $1/r$ del lado menor de la imagen, comenzando con $r = 1$, para filtrar la imagen de referencia I_{Ref} , posteriormente se reduce la máscara haciendo $r = 2$, se filtra la misma imagen y se evalúa la diferencia entre los valores filtrados de intensidad en el pixel P_{Qmax} cuyo valor sea el máximo sobre la imagen I_{Ref} sin filtrar. El proceso sigue incrementando a r con cada iteración hasta que la diferencia entre los últimos dos valores filtrados de intensidad en P_{Qmax} sea menor o igual al 10% del valor original de P_{Qmax} . Si $F_{med}^M(I)$ representa la operación de filtro mediana sobre la imagen I con una máscara cuadrada de lado M , la ecuación 2.4 sintetiza la meta del algoritmo anterior (Restrepo, 2013):*

$$\frac{\left| \Delta F_{med}^{\frac{1}{r}M_0} \left(I_{Ref}(P_{Qmax}) \right) - \Delta F_{med}^{\frac{1}{r-1}M_0} \left(I_{Ref}(P_{Qmax}) \right) \right|}{I_{Ref}(P_{Qmax})} \leq 0.1 \quad (2.4)$$

Donde:

$$\Delta F_{med}^k \left(I_{Ref}(P_{Qmax}) \right) = I_{Ref}(P_{Qmax}) - F_{med}^M \left(I_{Ref}(P_{Qmax}) \right) \quad (2.5)$$

- III. Con el propósito de reducir la duración, manteniendo al mismo tiempo la zona procesada durante el cálculo del valor mediana, se eligen, como opción, algunos pixeles de la región: *Cada pixel considerado está separado de sus vecinos analizados por una cantidad de ζ pixeles en las cuatro*

direcciones cardinales, como enseña la figura 2.7. Matemáticamente, si la ecuación 2.6 expresa la operación mediana (mediante la función *med*) sobre el pixel de coordenadas i,j de la imagen I : (Restrepo, 2013)




Figura 2.7 Ejemplo de máscara modificada para el filtro mediana diezmado (Restrepo, 2013).

$$F_{med}^M(I_{(P_{i,j})}) = med \left((I_{(P_{i+K_{Mi},j+K_{Mi}})}) | k_{Mi,j} \right. \\ \left. = -\left(\frac{\tilde{M}}{2}\right), -\left(\frac{\tilde{M}}{2}\right) + 1, -\left(\frac{\tilde{M}}{2}\right) + 2, \dots, -\left(\frac{\tilde{M}}{2}\right) \right) \quad (2.6)$$

Entonces, el filtrado mediana con diezmado se expresaría (Restrepo, 2013):

$$F_{med}^{M\zeta}(I_{(P_{i,j})}) = med \left((I_{(P_{i+K_{Mi},j+K_{Mi}})}) | k_{Mi,j} \right. \\ \left. = -\left(\frac{\tilde{M}}{2}\right), -\left(\frac{\tilde{M}}{2}\right) + \zeta, -\left(\frac{\tilde{M}}{2}\right) + 2\zeta, \dots, -\left(\frac{\tilde{M}}{2}\right) \right. \\ \left. + n\zeta \leq \left(\frac{\tilde{M}}{2}\right) \right) \quad (2.7)$$

Donde ζ es el factor de diezmado del filtro y el carácter (\tilde{X}) corresponde a la aproximación de X al entero más cercano por debajo. Se puede observar en la ecuación 2.6 que en el extremo derecho es muy probable que los últimos píxeles alrededor de la derecha y cerca del margen inferior de la máscara diezmada no correspondan con los últimos píxeles alrededor de la derecha y cerca del margen inferior de la máscara original de tamaño M , por lo que esto depende de la proporción entre M y ζ .

Con lo expuesto anteriormente se consigue incluir en el cálculo del valor filtrado para el píxel central de la máscara, un área cuadrada de la imagen de longitud igual a M píxeles, resultando una máscara de $M \times M$, en un intervalo de tiempo semejante a la aplicación del filtro mediana con una longitud de lado de M/ζ píxeles. Con la *máscara diezmada* y un número

impar de pixeles en sus lados, es indispensable ampliar la longitud de los lados de las secciones de la imagen en un ancho igual a $(M-1)/2$ pixeles deteniendo principalmente el valor de los pixeles de las secciones de la imagen original, antes de ejecutar el filtro.

- IV. La máscara diezmada compromete una zona que corresponde a una gran parte de la imagen, y por lo tanto, los bordes empiezan a ser afectados. Por consiguiente, para aumentar la eficacia de los resultados de la aplicación de filtro alrededor de los bordes, se realiza un procedimiento de extrapolación de tal forma que al propagarlos se mantenga la inclinación del comportamiento térmico en la proporción que se avanza hacia la periferia de cada imagen. El procedimiento, denominado *expansión lineal de bordes*, toma una fracción apropiada del contorno, o marco de base, de cada termograma, promediando la intensidad de los pixeles de las filas paralelas de cada lado del marco de la imagen y adapta los promedios resultantes de cada lado del marco a una recta mediante regresión lineal, la cual se toma como base y por extrapolación, se calculan los promedios que expondrían los pixeles situados en las filas después de los bordes si estas se consideran o existieran. *Las relaciones de proporción entre los promedios extrapolados y los valores de los pixeles del borde de la imagen, permiten estimar los valores de los pixeles de la región expandida* (Restrepo, 2013). Lo mencionado anteriormente se puede observar de forma esquematizada en la figura 2.8.




Figura 2.8 Ejemplo de la expansión de los bordes de un termograma (Restrepo, 2013).

- V. Después de la ejecución del filtrado de mediana sobre cada termograma de la secuencia original, resulta la secuencia de calentamiento de fondo que pertenece a la transformación de calor en la superficie de evaluación, al no mostrar defectos; en otras palabras, *llamando a esta secuencia de calentamiento como $S^c(t)$, y siendo f y c el total de filas y columnas de cada imagen respectivamente, se tiene* (Restrepo, 2013):

$$S^c(t) = F_{med}^{M,\zeta}(I_t(p_{i,j})), \forall i, j, t, \text{ con } i = 1 \dots f, j = 1 \dots c \quad (2.8)$$

En donde $S_{ij}(t)$ y $S_{ij}^c(t)$ corresponden a la secuencia original y de calentamiento de fondo, evaluadas en un pixel de coordenadas (i, j) . Para un tiempo (t) se obtiene la ecuación 2.9 para el contraste absoluto (Restrepo, 2013):

$$\Delta T_{CTFF}(t) = S_{ij}(t) - S_{ij}^c(t), \forall i, j, t \quad (2.9)$$

Implementando la ecuación 2.9 en todas las imágenes y realizando un barrido de t , se tiene como resultado la secuencia compensada. Se puede observar en la figura 2.9 una breve descripción gráfica del procedimiento de compensación, en donde a un termograma con varios defectos se le resta la imagen sin defectos para el mismo instante dando como resultado el termograma compensado (Restrepo, 2013).

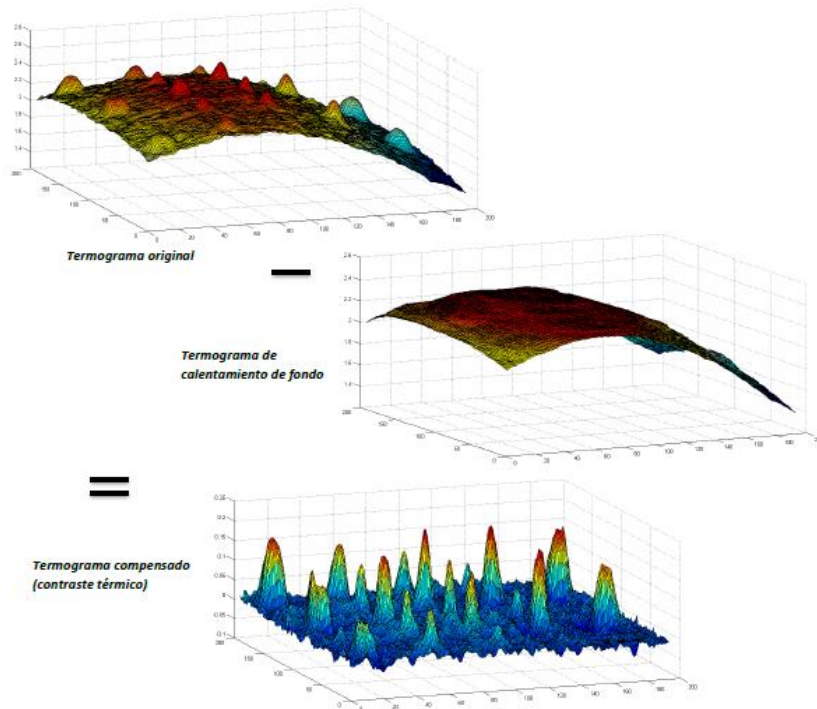


Figura 2.9 Comparación entre un termograma original, su perfil de calentamiento de fondo estimado y su versión contrastada (Restrepo, 2013).

2.5 Redes Neuronales

Un campo transcendental en la inteligencia artificial son las Redes Neuronales, por ser una técnica de modelado flexible basada en la emulación de los sistemas nerviosos biológicos. Se realiza en una computadora a través de un proceso adaptativo de aprendizaje, generando una herramienta exitosa para la solución de problemas reales con un grado elevado de dificultad. (Socha-Garzon & Ortiz, 2005) (Peña Gutiérrez, 2009).

Matemáticamente, las redes neuronales de *propagación hacia adelante con una sola capa oculta se expresan como un modelo de regresión lineal generalizada que considera una combinación lineal de transformaciones no lineales de las variables de entrada, con la siguiente expresión* (Idurre & Borja, 2005):

$$y(x, \theta) = \beta_0 + \sum_{j=1}^M \beta_j \beta_j(x, w_j) \quad (2.10)$$

En donde M corresponde al número de transformaciones no lineales, $\theta = \{\beta, w_1, \dots, w_M\}$ el conjunto de parámetros asociados al modelo, $\beta = \{\beta_0, \dots, \beta_M\}$ los parámetros asociados a la parte lineal del modelo, $\beta_j(x, w_j)$, cada una de las funciones de base en donde w_j es el conjunto de parámetros de cada función de base y $x = \{x_1, \dots, x_K\}$ las variables de entrada del problema (Idurre & Borja, 2005).

Otro punto importante es el aprendizaje de las redes neuronales, el cual se clasifica como supervisado y no supervisado. El aprendizaje supervisado consiste en un sistema que conoce o hace uso de un supervisor que indique si las decisiones tomadas por la red corresponden a la salida esperada. En esta clase de redes se debe definir un valor para un conjunto de parámetros θ , una arquitectura que consiste en establecer el número de neuronas que se desean, el número de capas y establecer un algoritmo como *BackPropagation* o Entropía cruzada, los cuales son escogidos a partir del tipo de problema que se desea solucionar. Para el aprendizaje no supervisado el sistema no posee un supervisor y por lo tanto encuentra la asociación del conjunto de datos que ingresan al sistema.

2.5.1 Red Perceptron Multicapa (MLP)

Esta red consiste en un algoritmo de aprendizaje supervisado que es definido por $f(\cdot): R^m \rightarrow R^0$ donde m corresponde a la dimensión de entradas y o a la dimensiones para la salida, para un grupo de características definido como $x = \{x_1, x_2, x_3, m\}$ y la salida se convierte en el objetivo según como lo defina el problema. Generalmente este algoritmo es utilizado como un aproximador de

funciones no lineales para clasificación o regresión. La figura 2.10 presenta el diagrama esquemático de la red MLP.




Figura 2.10 Red Neuronal Artificial, Perceptron Multicapa

2.5.2 Modelo Funcional para Problemas de Clasificación

Para resolver problemas de clasificación, la arquitectura mostrada en la figura 2.11 ha sido implementada en diferentes estudios, en donde se asigna a cada salida las distintas clases que se desean obtener.




Figura 2.11 Red Neuronal Artificial, Multicapa Perceptron con varias salidas. (Benítez H. , 2008)

Teniendo en cuenta el modelo funcional presentado en la ecuación 2.10 y dada la arquitectura de una red para clasificación, es apropiado hacer uso de nodos en la capa de salida en configuración *ad-hoc*. Una red neuronal *feedforward* típica (propagación hacia delante) hace uso de una función de activación lineal, mientras otras manejan un enfoque probabilístico, las cuales identifican una clase ganadora del resto de clases, tal como lo hace una red neuronal competitiva. Este último esquema difiere del método convencional *feedforward* en que la capa de salida emplea la función de activación *softmax* para cada uno de los nodos y utiliza un algoritmo de aprendizaje en el cual se maximiza la entropía cruzada. Mientras que

una red *feedforward*, a través del algoritmo de aprendizaje, busca minimizar el error cuadrático medio (MSE). Dado que las redes *feedforward* típicas, con salida lineal, son de amplio uso dentro de las aplicaciones con redes neuronales para la clasificación, su esquema de aprendizaje y ajuste de los pesos sinápticos a través del error cuadrático medio con el algoritmo *backpropagation* se explica con mayor detalle en (Caicedo & Sotelo, 2009).

2.5.2.1 Arquitectura *feedforward* de clasificación con enfoque probabilístico

Una arquitectura de clasificación con enfoque probabilístico se define matemáticamente por la función de activación *softmax* definida como (Idurre & Borja, 2005):

$$g_j(x, \theta_j) = \frac{e^{f_j(x, \theta_j)}}{\sum_{i=1}^J e^{f_i(x, \theta_i)}} \quad (2.11)$$

Esta función realiza estimaciones positivas para cada una de las clases, teniendo como resultado la suma de ellas. Por esta razón, se definen como la probabilidad de pertenencia a la clase correspondiente, así $g_j(x, \theta_j)$ representa la probabilidad de que el patrón x pertenezca a la clase j , y por consiguiente se puede comprobar que la clase pronosticada por la RNA, $C(x, \theta)$, es la correspondiente al nodo de la capa de salida cuyo valor es el mayor expresado funcionalmente como:

$$C(\theta, x) = \hat{l} \text{ donde } \hat{l} = \operatorname{argmax}_j g_j(x, \theta_j) = \operatorname{argmax}_j f_j(x, \theta_j), 1 \leq j \leq J \quad (2.12)$$

Teniendo en cuenta las consideraciones presentadas anteriormente, se obtiene el esquemático de la arquitectura de la RNA para problemas de clasificación en la Figura 2.12.

Finalmente, para establecer una medida que determine la respuesta del modelo se consideran dos funciones de aptitud: el porcentaje de patrones bien clasificados sobre el conjunto de entrenamiento, y la función de entropía cruzada del error. Al

considerar un grupo de entrenamiento $D=\{(x_n, y_n); 1 \leq n \leq N\}$, resulta la ecuación 2.13 que corresponde a la función de entropía para J categorías. Una ventaja al utilizar esta función es que proporciona un entrenamiento que converge hacia las soluciones más óptimas y robustas (Hervas, Gutiérrez, Carbonero, & Fernández, 2009).




Figura 12 Modelo de Red para problemas de clasificación. (Idurre & Borja, 2005)

$$l(\theta; g) = -\frac{1}{N} \sum_{n=1}^N \sum_{j=1}^J Y_n^{(j)} \log(g_j(x_n, \theta_1)) \quad (2.13)$$

2.6 Resumen

En este capítulo se presentó una revisión de la construcción y composición de los materiales compuestos, enfocándose en las láminas de plástico reforzadas con fibra de carbono; por otra parte, se realiza una descripción de la termografía infrarroja con sus ventajas y desventajas. Se muestran las principales técnicas para el procesamiento y análisis de datos con la termografía activa. Además, se presentan los contrastes térmicos CAD-m y CTFF: técnicas propuestas para realizar las clasificaciones con la red Perceptrón Multicapa, la cual se presenta en

este capítulo con dos tipos de algoritmos de aprendizaje basados en entropía cruzada- softmax y Error Cuadrático Medio (MSE), por sus siglas en inglés).

3. Metodología

3.1 Descripción del Sistema para la Extracción de Características

Las láminas CFRP utilizadas en este análisis fueron muestreadas y almacenadas en dos bancos de imágenes correspondientes a unas frecuencias de operación de 157 Hz y 90Hz. Las imágenes del primer y segundo banco tienen un área de 193x193x658 y 470x475x261 respectivamente, donde el primero y el segundo valor corresponden al ancho y alto de la imagen, mientras que el tercero corresponde al número de termogramas. Las imágenes fueron tomadas a partir de experimentos de termografía activa sobre dichas láminas, bajo el auspicio del grupo de investigación en Visión Infrarroja Multipolar (MIVIM), a las cuales se les aplica el contraste CTFF y CAD-m, se utilizó una interfaz gráfica denominada TermolR (Figura 3.1), fue desarrollada al interior del grupo PSI de la Universidad del Valle, y en la cual se encuentran diferentes tipos de contraste, incluyendo los mencionados anteriormente. En esta interfaz, cuando se establece el contraste que se desea aplicar al banco de secuencias, se ingresan los parámetros que se desean para cada uno de los contrastes. De esta manera, se obtuvieron los nuevos bancos de secuencia con contraste (Figura 3.2), a los cuales se realizó el estudio de la detección de profundidades de defectos.

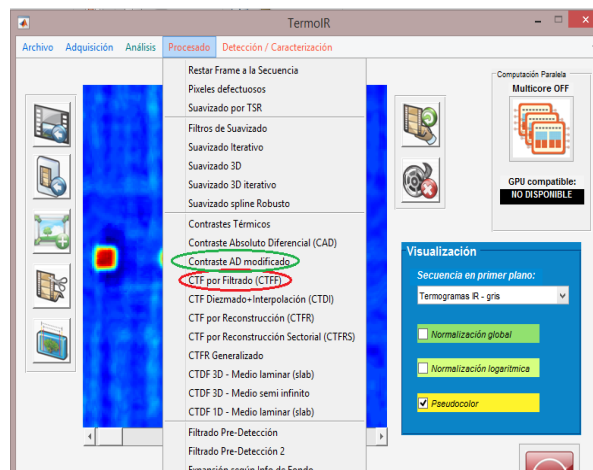


Figura 3.1 Interfaz gráfica TermolR




Figura 3.2 A) Secuencia original en el termograma 10, B) Secuencia con contraste CTFF en el termograma 10, C) Secuencia con contraste CAD-m en el termograma 10.

3.1.1 Extracción de Características

Teniendo en cuenta la descripción anterior se procedió a analizar los bancos de secuencia para la extracción de características. Para lo cual se realizó un pre-procesamiento en la secuencia: definir los límites inferior y superior de todos los termogramas. Se descartaron, los termogramas que se consideraron irrelevantes, se redujo la frecuencia de muestro a la cual se tomaron las muestras equidistantes de un sistema establecido, submuestreo o *downsampling*, mostrado esquemáticamente en la Figura 3.3 y definido en la ecuación 3.1.



Figura 3.3 Esquema de downsampling

$$Frecuencia_y = \frac{Frecuencia_x}{D} \quad (3.1)$$

En la figura 3.3 $X(n)$ corresponde al sistema de entrada con una $Frecuencia_x$, $Y(m)$ el sistema de salida con la frecuencia de muestreo deseada denominada $Frecuencia_y$ frecuencias que se utilizaran en la ecuación 3.1, y D que es el factor que divide la frecuencia original para obtener las muestras equidistantes y así obtener un sistema equivalente con diferente tasa de muestreo, como se puede observar en la figura 3.4

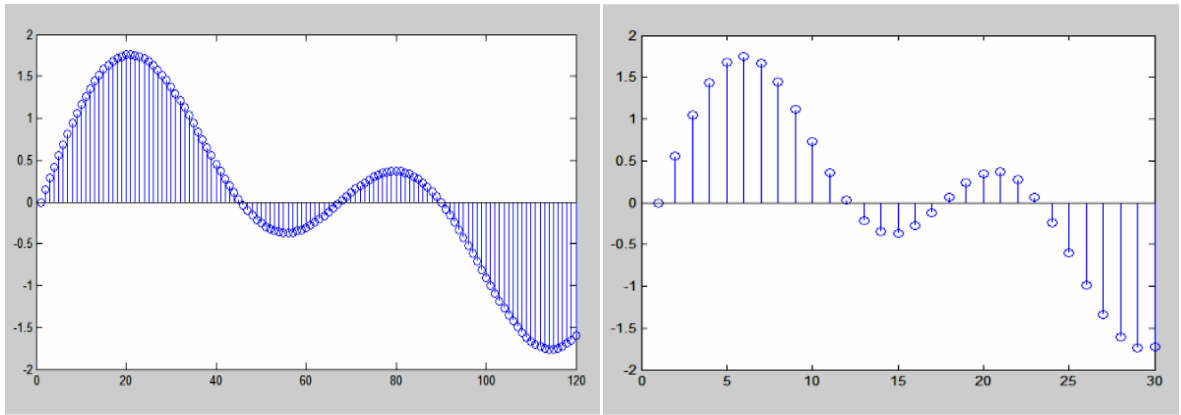


Figura 3.4 Señal original y señal con downsampling.

Para esta investigación, se realizó: un pre-procesamiento de los bancos de secuencias de 157Hz y 90Hz, se definieron los límites inferiores 10 y 3, los límites superiores 450 y 207, con factores de $D=15$ y 6.89, respectivamente estos valores se definieron con el método de ensayo y error con lo que se buscó un submuestreo que no afectara la clasificación. Aplicando el *downsampling* con los valores mostrados anteriormente se obtuvo una frecuencia de muestreo de 6.66Hz y 14.5Hz, obteniendo 30 termogramas por cada secuencia. Este número de termogramas no afectó el proceso de clasificación y redujo el número de características de los patrones de entrenamiento.

Con los resultados del pre-procesamiento aplicado a los bancos de secuencia se procedió a determinar las características de los patrones de entrenamiento. Para esto, se analizó el comportamiento de la temperatura en el tiempo por cada pixel a lo largo de la secuencia. Se observó que en el transcurso del enfriamiento de la placa, los pixeles donde se encuentran los defectos, presentan una variación importante de la temperatura de contraste. Utilizando estas variaciones como las características de los patrones, es posible construir un sistema que identifique diferentes clases de profundidad. Un ejemplo de un patrón adquirido en una secuencia de un pixel se presenta en la figura 3.5

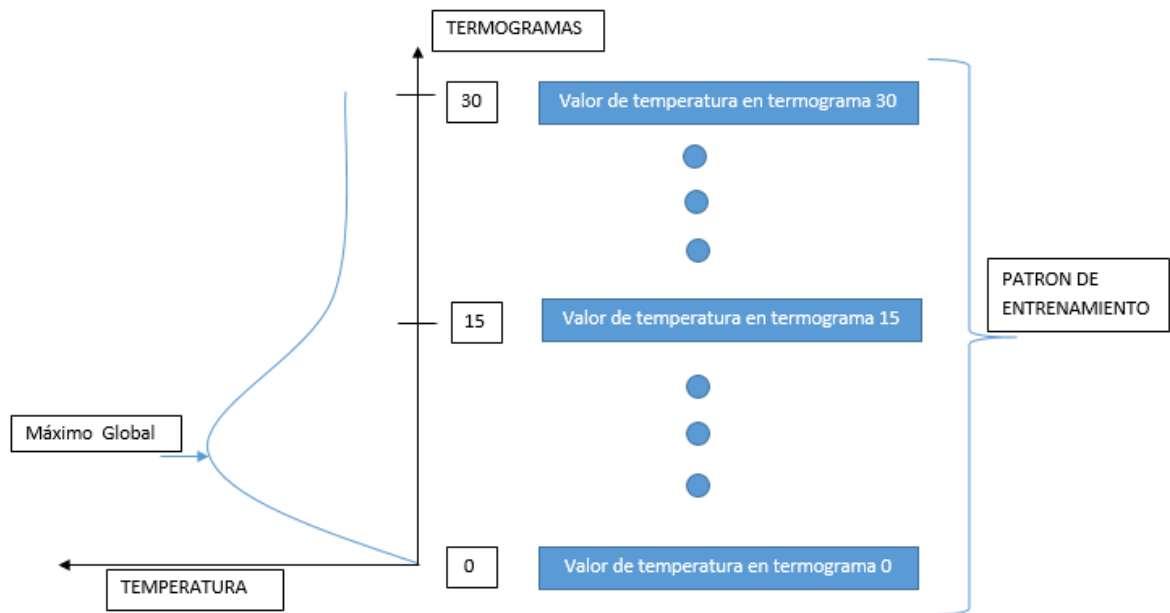


Figura 3.5 Esquema de extracción de características para cada pixel

3.1.2 Patrones de Entrenamiento

Para la construcción de un clasificador, una de las variables de mayor importancia es la dimensión del conjunto de entrenamiento, ya que de éste depende que pueda identificar correctamente las clases. Para este estudio, se tomó como referencia el estudio “Contribución a la Caracterización de Defectos en Termografía Infrarroja mediante Máquinas de Aprendizaje” (Benítez H. , 2008), en el cual se propone un conjunto de 600 patrones para su clasificación. Teniendo en cuenta el estudio referido, se propuso un conjunto de entrenamiento de 300 patrones de los cuales se asignaron 30 para cada profundidad, para un total de 150 defectos y 150 sanos. Se consideró que ésta era una muestra pequeña para realizar las clasificación de las 6 clases estudiadas y podría presentarse el fenómeno de *overfitting*; es decir, un ajuste muy bueno para los datos existentes, pero un bajo rendimiento para nuevos datos (Montes, "Website my works", 2009). Por lo anterior, fue conveniente aumentar la muestra a un total de 600 patrones. Los nuevos 300 datos fueron generados aplicando un ruido gaussiano aditivo de 8% a la primera muestra.

En la ecuación 3.2 se presenta la función matemática del ruido gaussiano, en donde σ es la desviación, μ es la media y x es un valor aleatorio seguido por la ecuación 3.3. Esta es la función matemática del ruido aditivo, y en la que se propuso una desviación de 0.08 y media igual a cero, para este trabajo. Estos parámetros fueron establecidos mediante el método de ensayo y error. Se observó que las muestras obtenidas correspondían a las variaciones aceptables para cada defecto y no defecto, dentro de la muestra, sin que esto alterara significativamente la clasificación. Figura 3.6

$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{\frac{-(x-\mu)^2}{2\sigma^2}} \quad (3.2)$$

$$\text{Ruido aditivo} = \text{patron} + p(x) \quad (3.3)$$




Figura 3.6 Señal original (izquierda)- Señal con ruido gaussiano (derecha).

3.2 Arquitectura de la Red Neuronal Artificial

Se eligió como método de clasificación la red perceptrón multicapa con una arquitectura conformada por una capa de entrada, una capa oculta, y una capa de salida, definidas de la siguiente forma:

- **Capa de entrada:** Se ingresó el conjunto de patrones, organizado como se muestra en la figura 3.7, generando 30 nodos correspondientes a las características extraídas por la variación de temperatura.
- **Capa Oculta:** Esta etapa es la que se encuentra más comprometida en el momento que se necesita construir un buen clasificador, pues consiste en definir el número más adecuado de neuronas. Ya que no existe un método que permita definir este número, se realizó un barrido de 3 hasta 30 neuronas. Por cada topología se ejecutaron 50 entrenamientos, Se definió un conjunto de patrones del 70% para el entrenamiento, el 15% para validación y el 15% de prueba. Con este barrido, se desea determinar cuál es la topología más adecuada. Para determinar la cantidad adecuada de neuronas se utilizó la información obtenida de los 50 entrenamientos: Error máximo, error mínimo, media, desviación estándar, y el diagrama de cajas de los errores resultantes por cada experimento. Se consideró un experimento el resultado de 50 entrenamientos para m -neuronas en la capa oculta, con $m = 3, 4, 5, \dots, 30$

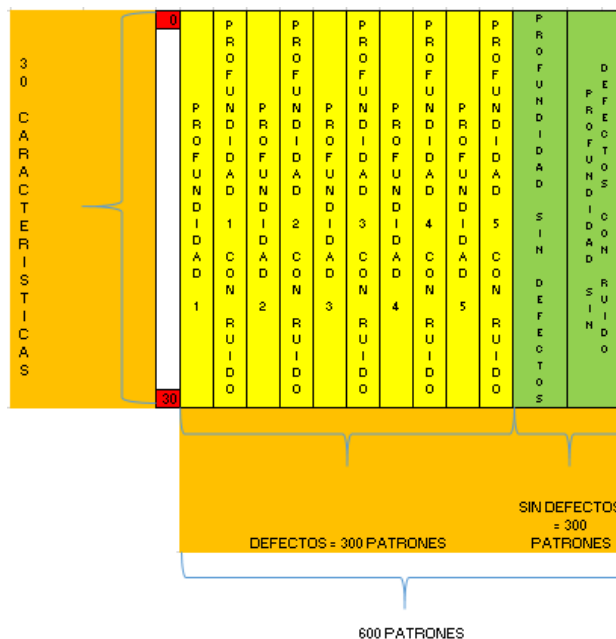


Figura 3.7 Conjunto de entrenamiento organizado para la capa de entrada.

- **Capa de salida.** Para esta etapa se define el número de clases que se desea que el clasificador identifique, con una función de activación que depende del tipo de algoritmo de aprendizaje. Para este estudio se definieron 6 clases que corresponden a 5 profundidades de defectos y una como no defectos.

Para comprobar la metodología propuesta anteriormente se escogió el algoritmo de entropía cruzada y el error cuadrático medio (MSE), métodos de clasificación ideales para este tipo de problemas. (Hervas, Gutiérrez, Carbonero, & Fernández, 2009) (Idurre & Borja, 2005).

Con los resultados obtenidos de los dos algoritmos se definió el número de neuronas más adecuado en la capa oculta para cada caso, por lo que se propuso realizar el filtrado de las mejores redes en tres partes: En el primer filtrado, se determinan las redes que se encuentran con los niveles más bajos del error; En el segundo filtrado, se verifican los diagramas de cajas de los errores de las redes resaltadas en la primera parte (primer filtrado). Se observa la dispersión de los datos y la mediana, valor del error en el cual se encuentran la mayor concentración de redes. Finalmente, en el tercer filtrado, se valida el desempeño de la redes escogidas en segundo filtrado, para determinar qué topologías presentan los mejores resultados a partir de la matriz de confusión.

3.3 Validación del Desempeño de la Red

Se eligió como método de validación el estudio de toda la lámina CFRP. Se extrajo el perfil térmico de cada pixel del banco de secuencia analizado, para ingresarlo como patrón de entrada de la red entrenada, escogida en el ítem anterior. Con el propósito de observar si la red obtiene una buena clasificación, se asignó a cada una de las salidas de la red un color para construir una nueva imagen de dimensiones iguales a la lámina estudiada. Esta se llenó con el color de acuerdo con su clasificación por cada pixel. Las imágenes ideales en este estudio deberían ser similares a las presentadas en la figura 3.8 que corresponden a las plantillas de defectos reales.




Figura 3.8 Plantilla real de defectos 157Hz(izquierda), Plantilla real de defectos 90Hz(derecha)

Con la plantilla generada, se estima la precisión del modelo de aprendizaje. Con este fin se utilizó, como herramienta de presentación y análisis de resultados, la **Matriz de Confusión**, por ser un método que permite definir los conflictos entre las diferentes clases, obtener un verdadero porcentaje de clasificación, y resultados confiables para cada una de las clases y sus principales inconvenientes.

La matriz de confusión es de dimensión $M \times M$ en donde M corresponde al número de clases. Para este caso, se obtiene una matriz de 6 x 6. A la cual se asignan los valores de la siguiente manera: En su diagonal, los aciertos de cada clase y por fuera de esta, los diferentes problemas en la clasificación, como se muestra en la figura 3.9.

		Clases Obtenidas					
Clases Actuales	CLASES	1	2	3	4	5	6
	1	Clase 1 como clase 1	Clase 1 como clase 2	Clase 1 como clase 3	Clase 1 como clase 4	Clase 1 como clase 5	Clase 1 como clase 6
	2	Clase 2 como clase 1	Clase 2 como clase 2	Clase 2 como clase 3	Clase 2 como clase 3	Clase 2 como clase 5	Clase 2 como clase 6
	3	Clase 3 como clase 1	Clase 3 como clase 2	Clase 3 como clase 3	Clase 3 como clase 4	Clase 3 como clase 5	Clase 3 como clase 6
	4	Clase 4 como clase 1	Clase 4 como clase 2	Clase 4 como clase 3	Clase 4 como clase 4	Clase 4 como clase 5	Clase 4 como clase 6
	5	Clase 5 como clase 1	Clase 5 como clase 2	Clase 5 como clase 3	Clase 5 como clase 4	Clase 5 como clase 5	Clase 5 como clase 6
	6	Clase 6 como clase 1	Clase 6 como clase 2	Clase 6 como clase 3	Clase 6 como clase 4	Clase 6 como clase 5	Clase 6 como clase 6

Figura 3.9 Matriz de confusión

Caso	Definición
Verdadero Positivo	Caso positivo etiquetado como positivo
Verdadero Negativo	Caso negativo etiquetado como negativo
Falso Positivo	Caso negativo etiquetado como positivo
Falso Negativo	Caso positivo etiquetado como negativo

Tabla 3.1 Resumen Matriz de confusión

A partir de la figura 3.9 se definen los 4 casos de la tabla 3.1, (Montes, "Website my works", 2014) que corresponde al resumen de la matriz de confusión, con el propósito de construir una estadística mejor elaborada, resumida en la figura 3.10. Para esto, se debe tener en cuenta que en este estudio se tienen más de dos clases; por consiguiente, es necesario determinar: Qué corresponde a positivo y qué corresponde a negativo, dónde se define como positivo a las clases de los defectos y dónde como negativo a la clase de no defectos.

	Clase Positivo	Clase Negativa
Positivo	Verdaderos Positivos	Falsos Negativos
Negativo	Falsos Positivos	Verdaderos Negativos

Figura 3.10 Resumen estadístico de Matriz de confusión

Con la figura 3.10 se puede obtener varias técnicas estadísticas descriptivas y analíticas, útiles para el análisis de resultados. Entre estas técnicas se encuentran: la precisión, la sensibilidad, la especificidad y la exactitud, las cuales son definidas en la figura 3.11 (Valdovinos, 2006), (Montes, "Website my works", 2014).

		Clases Obtenidas			
		Total Poblacion	Positivo	Negativo	
Clases Actuales	Positivo	Verdadero Positivo(VP)	Falso Negativo(FN)	Sensibilidad $\frac{VP}{VP + FN}$	Definición: Porcentaje de positivos correctamente identificados
	Negativo	Falso Positivo(FP)	Verdadero Negativo(VN)	Especificidad $\frac{VN}{FP + VN}$	Definición: Porcentaje de Negativos correctamente identificados
		Exactitud $\frac{VP + VN}{VP + FN + FP + VN}$	Precisión $\frac{VP}{VP + FP}$		
		Definición: Porcentaje de acierto con el total de la población	Definición: Proximidad de la clasificación a los valores reales		

Figura 3.11 Matriz de confusión con Técnicas estadísticas.

3.3.1 Protocolo de Pruebas para la validación de la estimación de profundidad de defectos en una lamina CFRP

A continuación se presenta el protocolo de pruebas para la validación de la estimación de profundidad de defectos en una lámina CFRP a partir de los resultados obtenidos durante el proceso de selección de la mejor topología y arquitectura de red neuronal entrenada, donde se requiere establecer el mejor algoritmo de aprendizaje, es decir, usando la métrica de MSE o la métrica de entropía cruzada.

1. Una vez identificada la mejor arquitectura para la red neuronal se procede a realizar clasificaciones de profundidades a partir de una nueva base de datos extraída del banco de secuencia en estudio.
2. Con los datos obtenidos de la clasificación, se construye una nueva lámina en la cual se reflejan las diferentes profundidades identificadas por los colores correspondientes a cada una.







Profundidad	Color		
0.02 mm	Azul rey		
0.04 mm	Azul agua marina		
0.06 mm	Verde		
0.08 mm	Naranja		
1.0 mm	Amarillo		
Zona sana	Azul oscuro		

Tabla 3.2 Asignación de colores para las diferentes profundidades

3. Con la lámina resultante se procede a construir la matriz de confusión respecto a la lámina real que usa los mismos colores presentados en la Tabla 3.2.
4. Con los resultados de la matriz de confusión se corrobora el porcentaje de sensibilidad alcanzado por el clasificador neuronal sin descartar las otras medidas.
5. Se verifican los resultados del clasificador a través de una inspección visual de la placa obtenida.

3.4 Resumen

En este capítulo se presentó el método propuesto para la caracterización de los defectos en los dos bancos de secuencias, para lo cual se usaron las técnicas de contraste CAD-m y CTFF. Posteriormente, se definieron las características del conjunto de entrada para las redes, así como los porcentajes de entrenamiento, validación y prueba. Se describió la estructura para el entrenamiento de la red MLP, con diferentes filtrados, para determinar la topología más apropiada para realizar el proceso de validación de los resultados; para ello se diseñó un protocolo de pruebas el cual hace uso de una plantilla de fallas que proporciona información de las profundidades para facilitar la inspección visual. El protocolo considera las diferentes métricas y definió el método de aprendizaje más apropiado para el entrenamiento de la red neuronal MLP.

4. Análisis y Resultados

En este capítulo se presenta los resultados del estudio de la detección de profundidades con las redes MLP para los dos bancos de secuencias de 157Hz y 90Hz. Se muestran algunas imágenes de los bancos de secuencias originales y de los nuevos bancos de secuencia con los contrastes CTFF y CAD-m. Posteriormente, se implementa la metodología indicando cual es la mejor topología para cada uno de los casos. Con las topologías obtenidas se ejecuta un protocolo de validación para identificar el algoritmo de aprendizaje más apropiado y finalmente se realiza un análisis comparativo con la técnica de contraste utilizada en el trabajo realizado por (Benítez H. , 2008).

A los dos bancos de secuencias (157Hz y 90Hz) mostrados en las figuras 4.1 y 4.2 se les aplicaron dos tipos de contraste CAD-m y CTFF de los cuales se obtuvo cuatro bancos de secuencias que se observan en las figuras 4.3 y 4.4 para el contraste CTFF y 4.5 y 4.6 para el contraste CAD-m.




Figura 4.1 Muestras original del Banco de secuencias de 157Hz.




Figura 4.2 Muestras original del Banco de secuencias de 90Hz.




Figura 4.3 Muestras del Banco de secuencias de 157Hz con CTFF.




Figura 4.4 Muestras del Banco de secuencias de 90Hz con CTFF.




Figura 4.5 Muestras del Banco de secuencias de 157Hz con CAD-m .




Figura 4.6 Muestras del Banco de secuencias de 90Hz con CAD-m.

Con el propósito de determinar el desempeño de las redes MLP y validar la metodología propuesta en el capítulo 3, se procedió a extraer los patrones de entrenamiento de los dos bancos de secuencias con el contraste CTFF. Una vez definido el conjunto de entrada de las redes, se ejecutó el barrido de 3 a 30 neuronas en la capa oculta, cada una de estas con 50 entrenamientos.

Aplicando la metodología propuesta para cada uno de los dos bancos de secuencias con contraste CTFF y los dos algoritmos de aprendizaje (Entropía cruzada con softmax y MSE) se obtuvieron cuatro tablas que contienen los errores cuadráticos medios de cada una de las redes entrenadas para cada caso. Con las tablas de resultados se calcularon las siguientes medidas: máximo y mínimo error, desviación estándar y media por cada topología, que se pueden observar en las figuras 4.7 y 4.8 para CTFF con entropía cruzada con softmax y 4.9 y 4.10 para CTFF con MSE, con las cuales se realiza el primer filtrado.

En la figura 4.7 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes redes con el barrido de neuronas de la capa oculta para el algoritmo de entropía cruzada con softmax a una frecuencia de 157Hz. En la figura 4.7 (Derecha) se observan los errores mínimos de cada una de las topologías, indicando con un cuadro las topologías seleccionadas las cuales se encuentran con valores de 0.0022 y 0.0027.




Figura 4.7 Resultados de los entrenamientos de la Red MLP (entropía cruzada y softmax) para el banco de secuencias de 157hz con CTFF (izquierda), Error mínimo (derecha).

En la figura 4.8 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes redes con el barrido de neuronas de la capa oculta para el algoritmo de entropía cruzada con softmax a una frecuencia de 90Hz. En la figura 4.8 (Derecha) se observan los errores mínimos de cada una de las topologías y en la cual se indican con un cuadro las topologías seleccionadas, las cuales se encuentran con valores de 0.




Figura 4.8 Resultados de los entrenamientos de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 90hz con contraste CTFF (derecha), Error mínimo (izquierda).

En la figura 4.9 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes redes con el barrido de neuronas de la capa oculta para el algoritmo de MSE a una frecuencia de 157Hz. En la figura 4.9 (Derecha) se observan los errores mínimos de cada una de las topologías y en la cual se indican con un cuadro las topologías seleccionadas, las cuales se encuentran con valores de 0.0033, 0.0035 y 0.0036.




Figura 4.9 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CTFF (derecha), Error mínimo (izquierda).

En la figura 4.10 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes redes con el barrido de neuronas de la capa oculta con el algoritmo de MSE para una frecuencia de 90Hz. En la figura 4.10 (Derecha) se observan los errores mínimos de cada una de las topologías y en la cual se indican las topologías seleccionadas, las cuales se encuentran con valores de 0.0023 y 0.0024.




Figura 4.10 Resultados de los entrenamientos de la Red MLP (MSE) para el banco de secuencias de 90hz con contraste CTFF (derecha), Error mínimo (izquierda).

Además, se realizó el diagrama de cajas para cada frecuencia y algoritmo de aprendizaje que contiene las siguientes medidas: mediana, límite superior o

máximo, límite inferior, tercer y primer cuartil, tal como se muestra en la figura 4.11 (Julio, 2008).




Figura 4.11 Diagrama de Caja.

En las figuras 4.12 y 4.13 se presentan los diagramas de cajas de CTFF para las secuencias con el algoritmo de entropía cruzada con softmax y en las figuras 4.14 y 4.15 se presentan los diagramas de cajas de CTFF para las secuencias usando el algoritmo MSE.

En cada una de las figuras anteriormente mencionadas se observan, en primera instancia, el valor del límite inferior, luego se observa la dispersión de los datos, la cual indica la homogeneidad de las redes obtenidas en cada topología. Posteriormente, y si la dispersión es alta, se analiza la simetría de los datos que corresponden a la mediana, las cuales deberían estar más cerca del nivel inferior para garantizar que la mayor parte de los resultados de aprendizaje se mantienen cerca a un error mínimo. Por último, se verifica que el límite superior se encuentre cerca al tercer cuartil.

El procedimiento previamente descrito corresponde al segundo mecanismo de filtrado, el cual permite agrupar el conjunto de topologías que mantuvieron cierta homogeneidad y que por ende, son las más apropiadas para ser utilizadas como clasificadores de profundidades. La Figura 4.12 muestra las topologías seleccionadas en un ovalo rojo siguiendo el procedimiento. Este mismo esquema de selección es utilizado y presentado en las Figuras 4.13, 4.14 y 4.15.




Figura 4.12 Diagrama de caja de los errores de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 157Hz con contraste CTFF.




Figura 4.13 Diagrama de caja de los errores de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 90Hz con contraste CTFF.




Figura 4.14 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 157Hz con contraste CTFF.




Figura 4.15 Diagrama de caja de los errores de la Red MLP (MSE) para el banco de secuencias de 90Hz con contraste CTFF.


En la tabla 4.1 se presentan los resultados de las dos primeras filtraciones para los dos algoritmos a las frecuencias de 157Hz y 90Hz. Se seleccionó con una X el número de neuronas que presentaron un mejor desempeño de acuerdo a los parámetros establecidos.

CTFF	Neuronas	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
MLP Entropia C. 157HZ	Filtrado 1			x	x	x	x		x		x		x	x	x	x		x		x	x		x	x		x		x	x
	Filtrado 2			x	x						x							x						x		x		x	
MLP Entropia C. 90HZ	Filtrado 1	x	x	x	x	x	x						x													x			
	Filtrado 2			x	x	x	x						x													x			
MLP MSE 157HZ	Filtrado 1			x		x		x		x					x										x				x
	Filtrado 2					x		x		x					x										x				x
MLP MSE 90HZ	Filtrado 1		x	x		x			x																				
	Filtrado 2		x	x		x			x																				


Tabla 4.1 Resultados del filtrado 1 y 2 para la selección de la mejor arquitectura

El tercer filtrado consiste en la validación de toda la lámina con las diferentes topologías de los dos algoritmos de aprendizaje para las frecuencias de 157Hz y 90Hz de la parte 2 (filtrado 2), generando su matriz de confusión.


En la figura 4.16 se presentan las matrices de confusión con 5, 6, 19, 25, 27 y 29 neuronas en la capa oculta de la red MLP con el algoritmo de entropía cruzada con softmax para el banco de secuencias de 157Hz con CTFF, donde se identifican dos clases: la primera de zona sana y la segunda en la que se identifican todos los defectos.




Resultado con 5 Neuronas en la capa oculta




Resultado con 6 Neuronas en la capa oculta




Resultado con 19 Neuronas en la capa oculta



Resultado con 25 Neuronas en la capa oculta




Resultado con 27 Neuronas en la capa oculta




Resultado con 29 Neuronas en la capa oculta

Figura 4.16 Matriz de confusión con 5,6,19,25,27,29 neuronas en la capa oculta de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 157hz con contraste CTFF.


En la figura 4.17 se presentan las matrices de confusión con 5, 6, 7, 8, 14 y 27 neuronas en la capa oculta de la red MLP con el algoritmo de entropía cruzada con softmax para el banco de secuencias de 90Hz con CTFF, en la cual se identifican dos clases: la primera de zona sana y la segunda en la que se identifican todas las profundidades.




Resultado con 5 Neuronas en la capa oculta




Resultado con 6 Neuronas en la capa oculta




Resultado con 7 Neuronas en la capa oculta



Resultado con 8 Neuronas en la capa oculta




Resultado con 14 Neuronas en la capa oculta



Resultado con 27 Neuronas en la capa oculta

Figura 4.17 Matriz de confusión con 5,6,7,8,14,27 neuronas en la capa oculta de la Red MLP (entropía cruzada y softmax) para el banco de secuencias de 90hz con contraste CTFF.


En la figura 4.18 se presentan las matrices de confusión con 7, 9, 11, 16, 26 y 30 neuronas en la capa oculta de la red MLP con el algoritmo MSE para el banco de secuencias de 157Hz con CTFF, en la cual se identifican dos clases: la primera de zona sana y la segunda en la que se identifican todas las profundidades.




Resultado con 7 Neuronas en la capa oculta




Resultado con 9 Neuronas en la capa oculta




Resultado con 11 Neuronas en la capa oculta



Resultado con 16 Neuronas en la capa oculta




Resultado con 26 Neuronas en la capa oculta




Resultado con 30 Neuronas en la capa oculta

Figura 4.18 Matriz de confusión con 7,9,11,16,26,30 neuronas en la capa oculta de la Red MLP (MSE) para el banco de secuencias de 157hz con contraste CTFF.


En la figura 4.19 se presentan las matrices de confusión con 4, 5, 7 y 10 neuronas en la capa oculta de la red MLP con el algoritmo MSE para el banco de secuencias de 90Hz con CTFF, en la cual se identifican dos clases: la primera de zona sana y la segunda en la que se identifican todas las profundidades.




Resultado con 4 Neuronas en la capa oculta



Resultado con 5 Neuronas en la capa oculta



Resultado con 7 Neuronas en la capa oculta



Resultado con 10 Neuronas en la capa oculta

Figura 4.19 Matriz de confusión con 4, 5, 7, 10 neuronas en la capa oculta de la Red MLP (MSE) para el banco de secuencias de 90hz con contraste CTFF.

Con las matrices de confusión obtenidas se construye la tabla 4.2 en la cual se especifican los valores de sensibilidad, precisión, especificidad y exactitud, para cada experimento. Con las métricas obtenidas de las matrices de confusión se seleccionan las mejores arquitecturas basados en el porcentaje de sensibilidad, que corresponden a los porcentajes de aciertos de las profundidades; sin embargo, en los casos que se presenta igual sensibilidad, se analizaron las otras variables, escogiendo finalmente la red con los porcentajes más cercanos al

100%. Las mejores topologías obtenidas se resaltan en la tabla 4.2 en color amarillo.

Contraste (CTFF)	Neuronas	Valores Matriz de Confusion				Medidas Estadísticas			
		VN	FN	FP	VP	Sensibilidad	Especificidad	Exactitud	Precisión
MLP (Entropia Cruzada con Softmax)157Hz	5	34523	59	1084	1583	96,4%	97,0%	96,9%	59,4%
	6	34624	50	983	1592	97,0%	97,2%	97,2%	61,8%
	19	34718	57	889	1585	96,5%	97,5%	97,5%	64,1%
	25	34669	54	938	1588	96,7%	97,4%	97,3%	62,9%
	27	34718	54	889	1588	96,7%	97,5%	97,5%	64,1%
	29	34623	51	984	1591	96,9%	97,2%	97,2%	61,8%
MLP (Entropia Cruzada con Softmax)90Hz	5	215468	78	2448	5256	98,5%	98,9%	98,9%	68,2%
	6	215338	96	2578	5238	98,2%	98,8%	98,8%	67,0%
	7	215486	108	2430	5226	98,0%	98,9%	98,9%	68,3%
	8	215201	87	2715	5247	98,4%	98,8%	98,7%	65,9%
	14	215743	101	2173	5233	98,1%	99,0%	99,0%	70,7%
	27	215823	110	2093	5224	97,9%	99,0%	99,0%	71,4%
MLP (MSE)157Hz	7	35486	366	121	1276	77,7%	99,7%	98,7%	91,3%
	9	35481	341	126	1301	79,2%	99,6%	98,7%	91,2%
	11	35480	346	127	1296	78,9%	99,6%	98,7%	91,1%
	16	35505	383	102	1259	76,7%	99,7%	98,7%	92,5%
	26	35496	380	111	1262	76,9%	99,7%	98,7%	91,9%
	30	35477	336	130	1306	79,5%	99,6%	98,7%	90,9%
MLP (MSE)90Hz	4	217732	1024	184	4310	80,8%	99,9%	99,5%	95,9%
	5	217624	980	292	4354	81,6%	99,9%	99,4%	93,7%
	7	217665	1012	251	4322	81,0%	99,9%	99,4%	94,5%
	10	217672	1031	244	4303	80,7%	99,9%	99,4%	94,6%

Tabla 4.2 Mejores arquitecturas para cada experimento con CTFF

De lo resultados presentados en la tabla anterior, se escogieron para la técnica de entropía cruzada con softmax a 157Hz 6 neuronas en la capa oculta con un porcentaje de estimación de profundidades del 97%, para una frecuencia de 90Hz se escogió 5 neuronas en la capa oculta con un porcentaje de estimación de profundidades del 98.5%. Para la técnica de MSE a 157Hz se escogieron 9 neuronas en la capa oculta con un porcentaje de estimación de profundidades del 79.2% descartando el valor de 30 neuronas debido a que el incremento en el porcentaje de estimación de profundidades no es significativo al costo computacional. Finalmente, para la misma técnica a una frecuencia de 90Hz se escogieron 5 neuronas en la capa oculta con un porcentaje de estimación de profundidades del 81.6%.

Con los resultados presentados en la tabla 4.2 se pudo observar que la técnica de entropía cruzada con softmax presenta un porcentaje de sensibilidad superior a la técnica de MSE. De acuerdo a lo anterior, se procedió a utilizar únicamente esta técnica para llevar a cabo el protocolo de comparación con la lámina real.

Las topologías obtenidas con entropía cruzada y softmax para los casos de 157Hz y 90Hz son entonces validados en cada pixel de la lámina para observar las profundidades calculadas por el clasificador neuronal. Este resultado se muestra en la figura 4.20.




Figura 4.20 Láminas resultantes izquierda 157Hz- derecha 90Hz

De la figura 4.20 se puede observar las seis profundidades que se identifican por medio de los colores: Amarillo (1 mm), Verde (0,6 mm), Azul rey (0,2 mm), Azul agua marina (0,4 mm), Naranja (0,8 mm) y Azul oscuro (Zona sana).

En la figura 4.21 se observan los errores externos (izquierda) e internos (derecha) encontrados en la clasificación de profundidades. La zona identificada con color blanco corresponde a los errores externos e internos presentados en las láminas CTFF a las frecuencias de 157Hz y 90Hz.

En las figuras 4.22 y 4.23 se presentan los datos de las matrices de confusión a 157Hz y 90Hz para CTFF y donde se corroboran los errores presentados en la figura 4.21. Sin embargo en las matrices de confusión de las figuras 4.22 y 4.23 se evidencian los errores para cada clase, donde la clase 1 corresponde a la zona sana y las clases 2 a 6 son las delaminaciones con diferentes profundidades de forma ascendente es decir: 0.02mm, 0,04mm, 0,06mm, 0,08mm y 1mm.




Figura 4.21 Errores en la estimación de profundidad de la lámina con CTFF a) Errores externos a las profundidades 157Hz b) Errores internos en las profundidades 157Hz c) Errores externos a las profundidades 90Hz d) Errores internos en las profundidades 90Hz.

Confusion Matrix 157Hz							
Output Class	1	2	3	4	5	6	
	34624 93.0%	0 0.0%	2 0.0%	13 0.0%	5 0.0%	30 0.1%	99.9% 0.1%
	265 0.7%	333 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	55.7% 44.3%
	139 0.4%	0 0.0%	330 0.9%	0 0.0%	0 0.0%	0 0.0%	70.4% 29.6%
	261 0.7%	0 0.0%	1 0.0%	311 0.8%	0 0.0%	0 0.0%	54.3% 45.7%
	91 0.2%	0 0.0%	0 0.0%	1 0.0%	301 0.8%	1 0.0%	76.4% 23.6%
	227 0.6%	0 0.0%	0 0.0%	3 0.0%	18 0.0%	293 0.8%	54.2% 45.8%
Target Class							
	1	2	3	4	5	6	97.2% 2.8%

Figura 4.22 Matriz de confusión 157Hz

Confusion Matrix 90Hz							
Output Class	1	2	3	4	5	6	
	215468 96.5%	4 0.0%	0 0.0%	4 0.0%	7 0.0%	63 0.0%	100.0% 0.0%
	343 0.2%	1143 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	76.9% 23.1%
	498 0.2%	0 0.0%	1041 0.5%	0 0.0%	0 0.0%	0 0.0%	67.6% 32.4%
	637 0.3%	0 0.0%	1 0.0%	1057 0.5%	3 0.0%	0 0.0%	62.2% 37.8%
	395 0.2%	0 0.0%	0 0.0%	4 0.0%	1018 0.5%	0 0.0%	71.8% 28.2%
	575 0.3%	0 0.0%	0 0.0%	0 0.0%	12 0.0%	977 0.4%	62.5% 37.5%
Target Class							
	1	2	3	4	5	6	98.9% 1.1%

Figura 4.23 Matriz de confusión 90Hz

4.1 Análisis comparativo

Para realizar una comparación entre técnicas de contrastes se debe tener una igualdad de parámetros. Debido a que se seleccionó el algoritmo de aprendizaje más eficiente que fue el de entropía cruzada con softmax, se propuso implementar la siguiente metodología:

1. Implementar la metodología propuesta en el tercer capítulo únicamente con la técnica de entropía cruzada con softmax, para definir la mejor topología para el contraste CAD-modificado.
2. Para determinar qué contraste presenta mejores resultados, se observaron los errores presentados a los cuales se les realizó un conteo para tener el número exacto de pixeles mal clasificados presentados de manera porcentual.
3. Por último, se ejecutó la validación para CTFF y CAD-m como la implementada por Hernán Benítez, la cual consiste en la clasificación de defectos para dos nuevas láminas CFRP que tienen las siguientes formas: Cóncava (CFRP007) y segmenta (CFRP008) (Figura 4.24, izquierda y derecha, respectivamente). Los resultados son presentados en la sección 4.1.1.




Figura 4.24 Esquemático laminas CFRP007(izquierda) -CFRP008(derecha) con intercesiones de teflón a) vista frontal b) vista lateral (Benítez H. , 2008)

Una vez definido el método para desarrollar el análisis comparativo con el contraste CAD-m se procedió a realizar el entrenamiento de las redes como se indicó para el contraste CTFF en donde se obtuvieron las figuras 4.25 y 4.26 correspondientes a la frecuencia de 157Hz y 90Hz, respectivamente.

En la figura 4.25 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes topologías para el algoritmo de entropía cruzada con softmax a una frecuencia de 157Hz. En la figura 4.25 (Derecha) se observan los errores mínimos de cada una de las topologías, en la cual se indican con un rectángulo las topologías seleccionadas, las cuales tienen valores de 0.

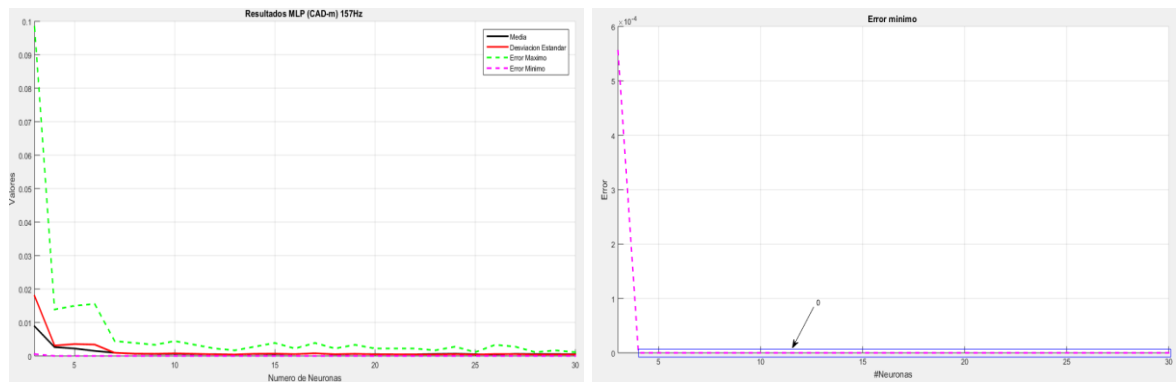


Figura 4.25 Resultados de los entrenamientos de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 157Hz con CAD-m (derecha), Error mínimo (izquierda).

En la figura 4.26 (Izquierda) se observa los resultados obtenidos de los entrenamientos de las diferentes topologías para el algoritmo de entropía cruzada con softmax a una frecuencia de 90Hz. En la figura 4.26 (Derecha) se observan los errores mínimos de cada una de las topologías, en la cual se indican con un cuadro las topologías seleccionadas, las cuales tienen valores de 0.




Figura 4.26 Resultados de los entrenamientos de la Red MLP (entropía cruzada con softmax) para el banco de secuencias de 90Hz con CAD-m (derecha), Error mínimo (izquierda).

En las figuras 4.27 y 4.28 se presentan los diagramas de cajas de CAD-m con el algoritmo de entropía cruzada con softmax y se seleccionaron las topologías resaltadas con el ovalo rojo.




Figura 4.27 Diagrama de Cajas con Contraste CAD-m para 157Hz




Figura 4.28 Diagrama de Cajas para 90Hz con Contraste CAD-m

Como se puede observar, al aplicar el contraste CAD-m las redes presentan un error mínimo de cero; es decir, que realiza una buena clasificación respecto a los datos de entrenamiento, lo que conlleva a que en la primera parte del procedimiento no se puedan descartar ninguna de las topologías para ambas frecuencias. Por otro lado, la segunda parte del procedimiento permitió suprimir algunas de ellas haciendo el respectivo análisis de dispersión de los datos y la mediana. Finalmente con la tabla 4.3 se determinan las topologías ganadoras.

CAD-m	Neuronas	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
MLP Entropia C. 157HZ	Filtrado 1		x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
	Filtrado 2							x	x		x	x	x	x	x		x		x	x	x			x	x			x	
MLP Entropia C. 90HZ	Filtrado 1	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
	Filtrado 2														x	x	x	x	x	x	x	x	x	x	x	x	x	x	x

Tabla 4.3 Resultados del filtrado 1 y 2 para la selección de la mejor arquitectura para CAD-m

Con los datos presentados en la tabla 4.3, se procedió a realizar la validación de la lámina para construir la matriz de confusión y mostrar los valores en la tabla 4.4 que contiene la sensibilidad, especificidad, exactitud y precisión. De esta manera se determina la mejor topología, la cual es seleccionada inicialmente por la sensibilidad. En los casos que se presenta una sensibilidad igual se analizan las otras variables, escogiendo finalmente la red con los porcentajes más cercanos a 100%.

Contraste (CAD-m)	Neuronas	Valores Matriz de Confusion				Medidas Estadísticas			
		VN	FN	FP	VP	Sensibilidad	Especificidad	Exactitud	Precisión
MLP (Entropia Cruzada con Softmax)157Hz	9	34322	31	1285	1611	98,1%	96,4%	96,5%	55,6%
	10	34285	48	1322	1594	97,1%	96,3%	96,3%	54,7%
	12	34370	50	1237	1592	97,0%	96,5%	96,5%	56,3%
	13	34463	47	1144	1595	97,1%	96,8%	96,8%	58,2%
	14	34630	51	977	1591	96,9%	97,3%	97,2%	62,0%
	15	34556	52	1051	1590	96,8%	97,0%	97,0%	60,2%
	16	34736	55	871	1587	96,7%	97,6%	97,5%	64,6%
	18	34598	56	1009	1586	96,6%	97,2%	97,1%	61,1%
	20	34592	68	1015	1574	95,9%	97,1%	97,1%	60,8%
	21	34568	47	1039	1595	97,1%	97,1%	97,1%	60,6%
	22	34582	59	1025	1583	96,4%	97,1%	97,1%	60,7%
	25	34664	47	943	1595	97,1%	97,4%	97,3%	62,8%
	26	34606	49	1001	1593	97,0%	97,2%	97,2%	61,4%
MLP (Entropia Cruzada con Softmax)90Hz	29	34736	65	871	1577	96,0%	97,6%	97,5%	64,4%
	16	211611	57	6305	5277	98,9%	97,1%	97,2%	45,6%
	17	211514	55	6402	5279	99,0%	97,1%	97,1%	45,2%
	18	209866	48	8050	5286	99,1%	96,3%	96,4%	39,6%
	19	209805	50	8111	5284	99,1%	96,3%	96,3%	39,4%
	20	211050	54	6866	5280	99,0%	96,8%	96,9%	43,5%
	21	209943	55	7973	5279	99,0%	96,3%	96,4%	39,8%
	22	211288	53	6628	5281	99,0%	97,0%	97,0%	44,3%
	23	211774	65	6142	5269	98,8%	97,2%	97,2%	46,2%
	24	212789	72	5127	5262	98,7%	97,6%	97,7%	50,6%
	25	211723	59	6193	5275	98,9%	97,2%	97,2%	46,0%
	26	211497	58	6419	5276	98,9%	97,1%	97,1%	45,1%
	27	209023	47	8893	5287	99,1%	95,9%	96,0%	37,3%
	28	210693	59	7223	5275	98,9%	96,7%	96,7%	42,2%
	29	211438	63	6478	5271	98,8%	97,0%	97,1%	44,9%
	30	210502	54	7414	5280	99,0%	96,6%	96,7%	41,6%

Tabla 4.4 Mejor arquitectura para experimentos con CAD-m

Las mejores topologías obtenidas, conforme a la tabla 4.4, son: para la frecuencia de 157Hz con 9 neuronas en la capa oculta y para la frecuencia de 90Hz con 18 neuronas en la capa oculta. Las láminas resultantes son presentadas en la figura 4.29 para ambos casos, donde se pueden identificar las 6 profundidades de las láminas usando el esquema de colores de la tabla 3.2.




Figura 4.29 Láminas resultantes con CAD-m, izquierda 157Hz- derecha 90Hz




Figura 4.30 Errores en la estimación de profundidad de la lámina con CAD-m a) Errores externos a las profundidades 157Hz b) Errores internos en las profundidades 157Hz c) Errores externos a las profundidades 90Hz d) Errores internos en las profundidades 90Hz.

La figura 4.30 presenta los errores externos e internos en la estimación de profundidades de la lámina a las frecuencias de 157Hz y 90Hz.

En las figuras 4.31 y 4.32 se presentan los datos de las matrices de confusión a 157Hz y 90Hz para el CAD-m y en las cuales se puede corroborar los errores que se presentan en la figura 4.30. Sin embargo en las matrices de confusión de las figuras 4.31 y 4.32 se evidencian los errores para cada clase, donde la clase 1 corresponde a la zona sana y las clases 2 a 6 son las delaminaciones con diferentes profundidades de forma ascendente es decir: 0.02mm, 0,04mm, 0,06mm, 0,08mm y 1mm.

Output Class	1	2	3	4	5	6	
1	34322 92.1%	0 0.0%	0 0.0%	2 0.0%	1 0.0%	28 0.1%	99.9% 0.1%
2	226 0.6%	333 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	59.6% 40.4%
3	198 0.5%	0 0.0%	331 0.9%	0 0.0%	0 0.0%	0 0.0%	62.6% 37.4%
4	363 1.0%	0 0.0%	2 0.0%	326 0.9%	0 0.0%	0 0.0%	47.2% 52.8%
5	371 1.0%	0 0.0%	0 0.0%	0 0.0%	323 0.9%	9 0.0%	45.9% 54.1%
6	127 0.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	287 0.8%	69.3% 30.7%
	96.4% 3.6%	100% 0.0%	99.4% 0.6%	99.4% 0.6%	99.7% 0.3%	88.6% 11.4%	96.4% 3.6%
Target Class	1	2	3	4	5	6	

Figura 4.31 Matriz de confusión de 157Hz con
CAD-m

Output Class	1	2	3	4	5	6	
1	209866 94.0%	4 0.0%	0 0.0%	1 0.0%	8 0.0%	35 0.0%	100.0% 0.0%
2	840 0.4%	1143 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.6% 42.4%
3	251 0.1%	0 0.0%	1035 0.5%	0 0.0%	0 0.0%	0 0.0%	80.5% 19.5%
4	1364 0.6%	0 0.0%	7 0.0%	1064 0.5%	0 0.0%	0 0.0%	43.7% 56.3%
5	631 0.3%	0 0.0%	0 0.0%	0 0.0%	886 0.4%	3 0.0%	58.3% 41.7%
6	4964 2.2%	0 0.0%	0 0.0%	0 0.0%	146 0.1%	1002 0.4%	16.4% 83.6%
	96.3% 3.7%	99.7% 0.3%	99.3% 0.7%	99.9% 0.1%	85.2% 14.8%	96.3% 3.7%	96.3% 3.7%
Target Class	1	2	3	4	5	6	

Figura 4.32 Matriz de confusión de 90Hz con
CAD-m

Para seleccionar la técnica de contraste que presenta los mejores resultados de estimación de profundidades de defectos en láminas CFRP se realizó un conteo de pixeles mal clasificados en las láminas, que se presentaron en las figuras 4.21 y 4.30, los cuales se representan porcentualmente en la tabla 4.5.

Contraste	Tipo de Error	157Hz	90Hz
CAD-m	Errores Externos a las profundidades	3,62%	3,76%
	Errores Internos en las profundidades	2,44%	0,96%
CTFF	Errores Externos a las profundidades	2,83%	1,13%
	Errores Internos en las profundidades	3,11%	1,52%

Tabla 4.5 Numero de pixeles mal clasificados.

En la tabla 4.5 se presentan el porcentaje de píxeles mal clasificados para los dos contrastes donde se concluye que los errores externos presentados en CAD-m son relativamente mayores que los errores del contraste CTFF. Esto demuestra que el contraste CTFF es una técnica que presenta mejores resultados que la técnica CAD-m, aunque esta última haya presentado resultados menores en los errores internos.

Con la tabla 4.5 se determinó que la técnica de contraste con menores porcentajes de error es el contraste mediante filtrado de fondo – CTFF, afirmando que es la mejor técnica para la detección y estimación de profundidad de defectos. Por otra parte, se puede observar que el contraste CAD-m presenta menos errores en la parte interna de la profundidad; pero, presenta demasiados errores para las zonas sanas, en relación al contraste CTFF.

Por otra parte, en el contorno de cada defecto se detecta una profundidad mayor, que podría ser causado por las secuelas de las delaminaciones y la dispersión lateral de calor, tal como se observa en la figura 4.33. Además, se puede detallar que el contorno que está clasificando la Red Neuronal en las láminas resultantes se encuentra presente en las láminas con contraste como se presentaron en las figuras 4.3 y 4.6, donde se observaba una muestra del banco de secuencias con los contrastes CTFF y CAD-m.




Figura 4.33 Clasificación de defectos de 15mm organizados de manera ascendente respecto a la profundidad.

Con la presentación de resultados y el análisis de las diferentes causas de los errores en la clasificación, se realizó el análisis comparativo con el trabajo de (Benítez H. , 2008), quien presenta el contraste CAD-modificado para la detección y caracterización de defectos. Debido a que Benítez realizó el estudio únicamente

con el banco de secuencias de 157Hz, se adicionó el estudio para el banco de secuencias de 90Hz con el propósito de determinar si la resolución influye en la clasificación.

4.1.1 Validación con Láminas Diferentes

Con base en la primera parte del capítulo 4, se pudo concluir que el mejor contraste es CTFF, implementando la metodología propuesta; pero se tuvo en cuenta que Hernán Benítez valida el funcionamiento de la red realizando la clasificación de defectos en dos placas nuevas.

Teniendo en cuenta lo mencionado anteriormente, se procedió a realizar la validación de las dos placas CFRP007 y CFRP008, como lo realizó Benítez utilizando la frecuencia de 157Hz. Debido a que no se contó con los elementos necesarios para realizar un análisis estadístico como se propuso en la metodología para determinar la mejor topología y generar la plantilla resultante, se propuso utilizar las cinco redes que generaron los mejores porcentajes de sensibilidad, exactitud, especificidad y precisión para los contrastes CTFF y CAD-M presentados en las tablas 4.2 y 4.4, obteniendo la tabla 4.6.

Contraste (CTFF)	Neuronas	Valores Matriz de Confusion				Medidas Estadísticas			
		VN	FN	FP	VP	Sensibilidad	Especificidad	Exactitud	Precisión
CTFF	6	34624	50	983	1592	97,0%	97,2%	97,2%	61,8%
	19	34718	57	889	1585	96,5%	97,5%	97,5%	64,1%
	25	34669	54	938	1588	96,7%	97,4%	97,3%	62,9%
	27	34718	54	889	1588	96,7%	97,5%	97,5%	64,1%
	29	34623	51	984	1591	96,9%	97,2%	97,2%	61,8%
CAD-M	9	34322	31	1285	1611	98,1%	96,4%	96,5%	55,6%
	13	34463	47	1144	1595	97,1%	96,8%	96,8%	58,2%
	21	34568	47	1039	1595	97,1%	97,1%	97,1%	60,6%
	25	34664	47	943	1595	97,1%	97,4%	97,3%	62,8%
	26	34606	49	1001	1593	97,0%	97,2%	97,2%	61,4%

Tabla 4.6 Redes que se utilizaron para generar la lámina Resultante de CFRP007 y CFRP008

Con las redes presentadas en la tabla 4.6, se construyeron las láminas con las topologías determinadas, las cuales son presentas en la figura 4.34 para CFRP007 y en la figura 4.35 para CFRP008 con CTFF

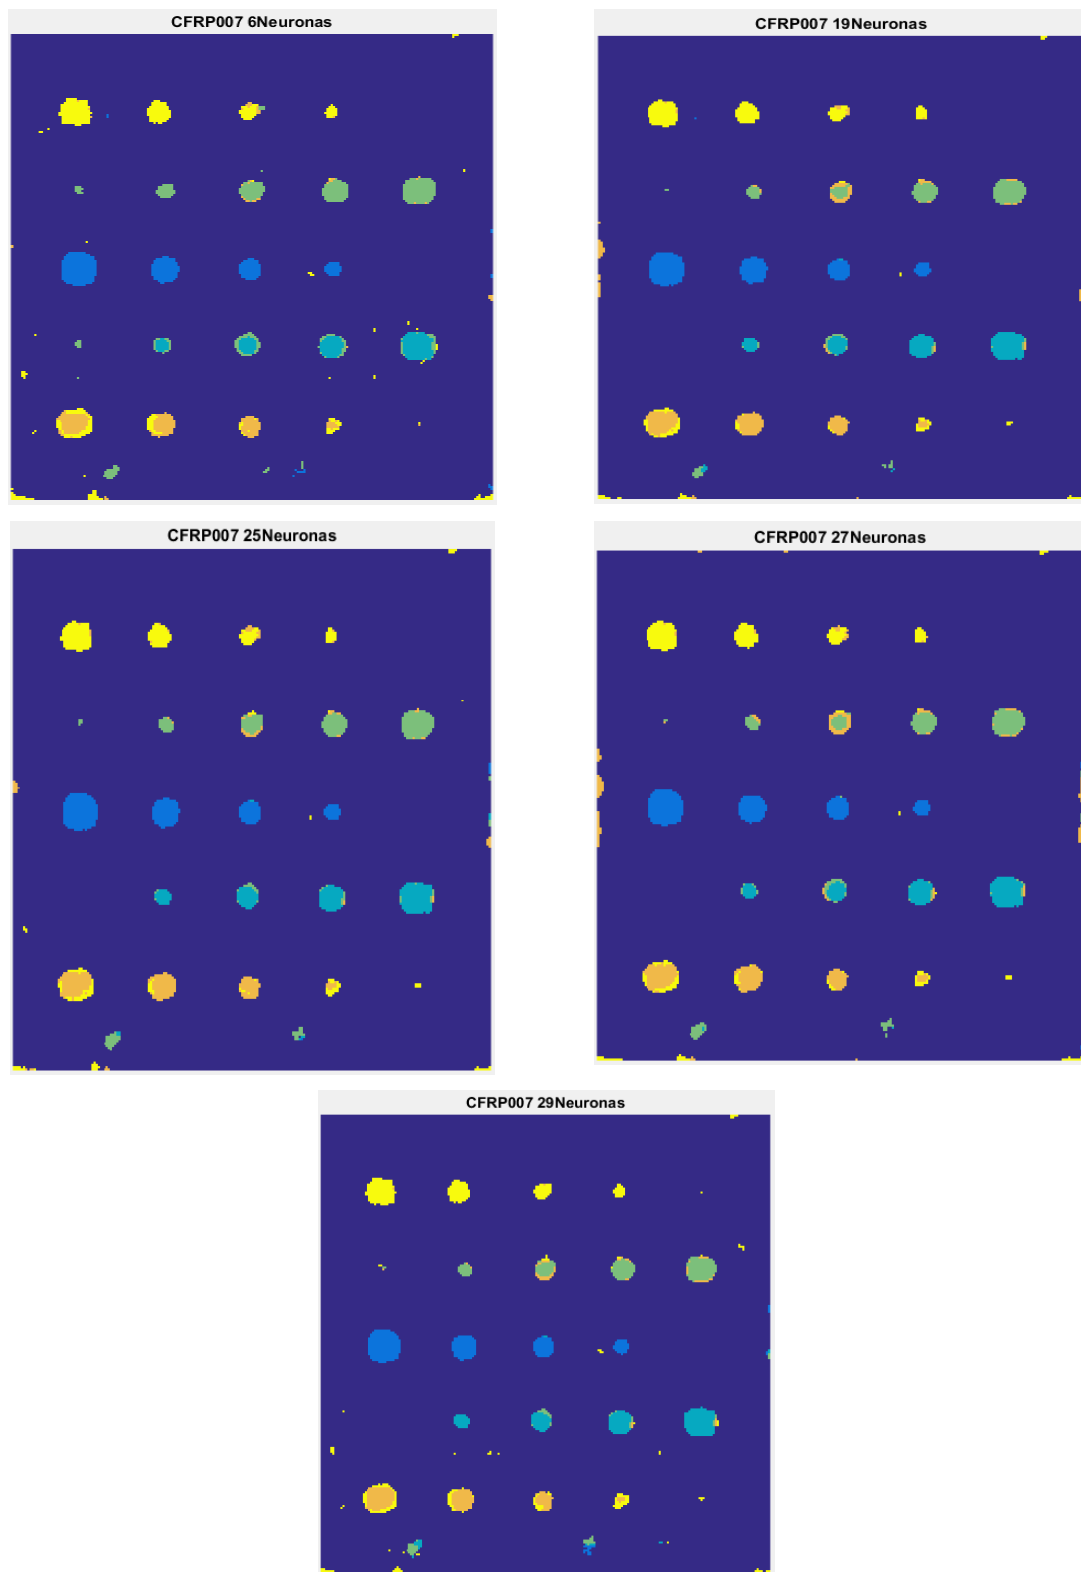


Figura 4.34 Laminas Obtenidas (CFRP007) con CTFF usando las topologías seleccionadas.

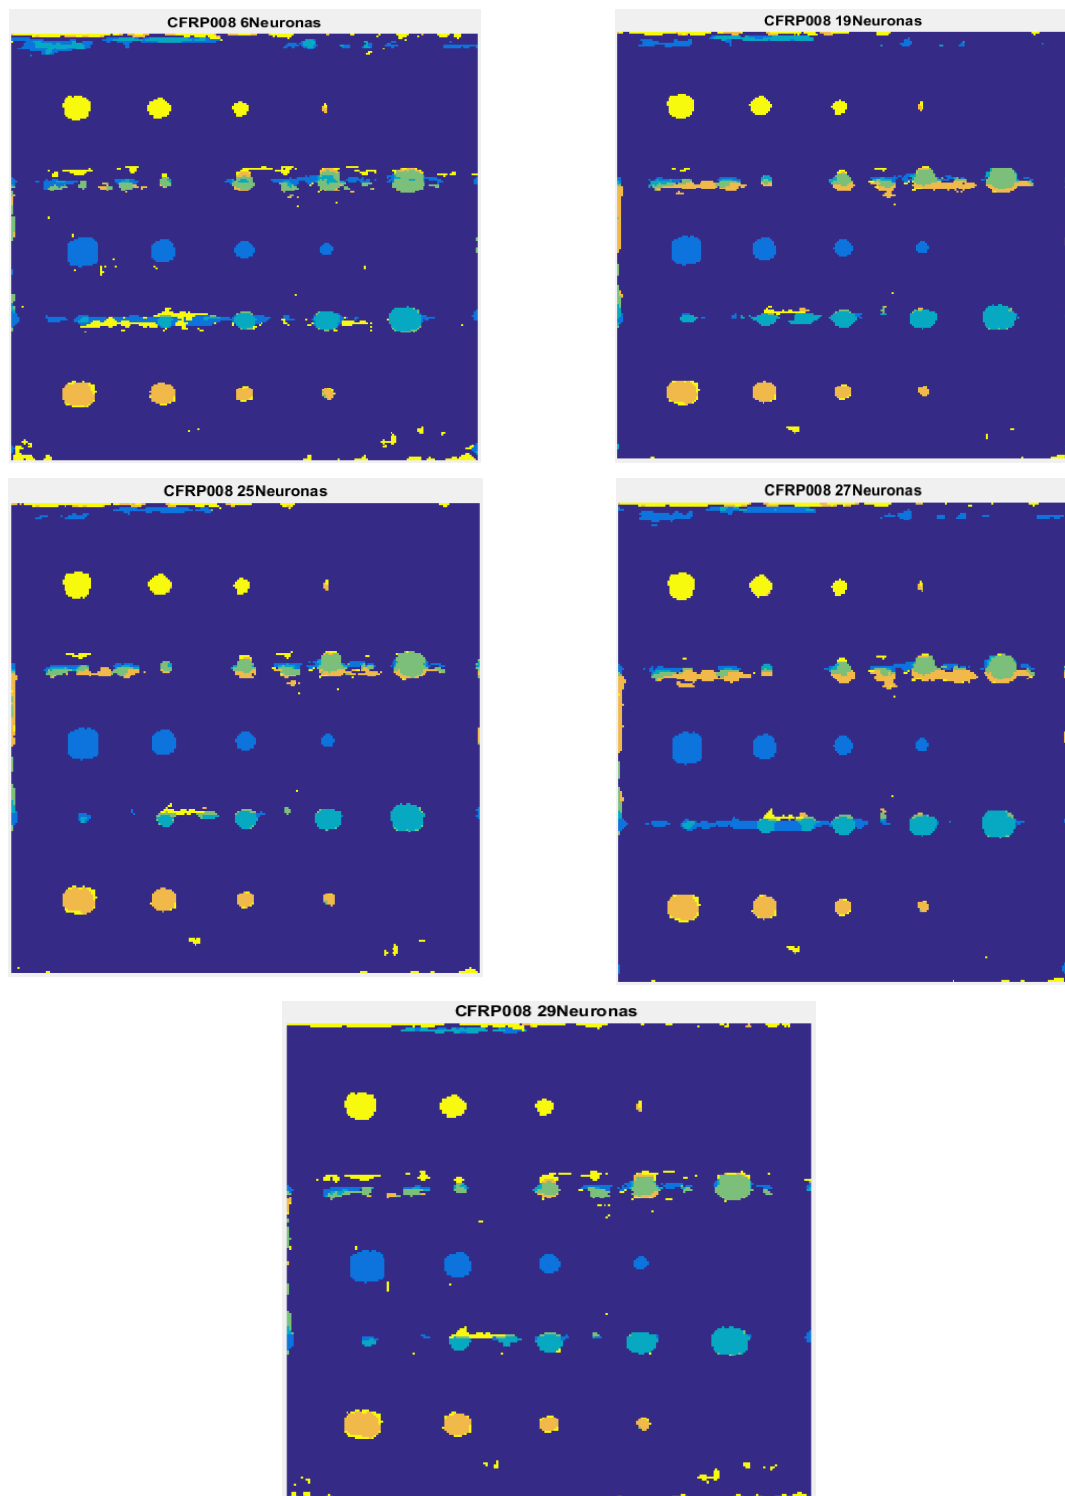


Figura 4.35 Laminas obtenidas (CFRP008) con CTFF usando las topologías seleccionadas.

En la figura 4.34 se pudo observar que el contraste CTFF presentó buenos resultados en concordancia con los esquemáticos presentados en la figura 4.24 (izquierda) que corresponde a la lámina CFRP007. Sin embargo, no se pudo establecer un porcentaje de acierto debido a que no se cuenta con una lámina de referencia para CFRP007. Lo mencionado anteriormente también se pudo observar en la figura 4.35 que corresponde a la lámina CFRP008 y al esquemático de la figura 4.24 (derecha). Cabe aclarar que las delaminaciones de las dos láminas están en las profundidades de 0,02mm, 0,04mm, 0,06mm, 0,08mm, y 1mm al igual que el estudio realizado previamente.

El procedimiento anterior se repite para el método de contraste CAD-m. Las figuras 4.36 y 4.37 se presentan las láminas obtenidas con el contraste CAD-m, donde la figura 4.36 presenta los resultados de la validación de la lámina CFRP007, mientras que la figura 4.37 muestra los resultados para la lámina CFRP008.

Con los resultados de las topologías seleccionadas en la lámina CFRP007 se observa que la técnica de contraste CAD-m presenta mayores pérdidas de información en las láminas resultantes, donde solo la topología con 13 neuronas en la capa oculta adquiere un buen resultado respecto a las otras. La misma topología resulta más apropiada usando la técnica de contraste CAD-m para el caso de la lámina CFRP008. De lo anterior, se concluye que la técnica CAD-m proporciona un contraste de alta sensibilidad ya que las topologías son susceptibles a las dispersiones de calor en las zonas sanas.




Figura 4.36 Laminas Obtenidas (CFRP007) con CAD-m




Figura 4.37 Laminas Obtenidas (CFRP008) con CAD-m

4.2 Resumen

En este capítulo se ejecutó la metodología propuesta en el capítulo 3 determinando que el algoritmo de aprendizaje que presentó mejores resultados es el de entropía cruzada con softmax, el cual tiene un error de clasificación para el CTFF del 2.8% para la frecuencia de 157Hz y de 1.1% para 90Hz. También se presentó un análisis comparativo con el contraste CAD-m que fue implementado por Benítez, con el cual se aplicó la misma metodología, obteniendo un error del 3.5% para 157Hz y de 3.6% para 90Hz, por lo que se define que el mejor contraste para realizar la estimación de profundidades de defectos es el contraste CTFF. Por último, se realizó la validación en dos láminas nuevas con lo cual se pudo corroborar que CTFF es mejor y que el algoritmo de entropía cruzada con *softmax* es una técnica más robusta para la clasificación de defectos en láminas compuestas de fibra de carbono.

5. Conclusiones y Trabajos Futuros

5.1 Conclusiones

- ❖ A partir de la revisión de los elementos conceptuales preliminares, se pudo determinar los criterios a tener en cuenta para la implementación de las redes neuronales, resaltando las características que se utilizaron como patrones de entrenamiento para la red, además de tener una referencia de los alcances logrados por los autores en el campo de la termografía para la detección y caracterización de defectos.
- ❖ A través de la implementación de técnicas de extracción o reducción de características como *downsampling* se logró presentar un conjunto de características suficiente para el procesamiento, detección y estimación de profundidades en los defectos mecánicos de las láminas CFRP, tal que el sistema de clasificación neuronal presentó resultados con altos porcentajes de sensibilidad.
- ❖ Se realizó la validación del sistema de detección de profundidad propuesto con la clasificación de nuevas muestras de la lámina, es decir patrones que no fueron utilizados para el entrenamiento, validación y prueba en el momento del aprendizaje.
- ❖ Para realizar la comparación de contraste CAD-m con CTFF se debe tener en cuenta que las condiciones de implementación para los dos contrastes deben ser iguales. Una vez desarrollada la metodología con los dos contrastes se pudo evidenciar en los resultados obtenidos que el contraste CTFF es una técnica superior para la estimación de profundidades, encontrándose un porcentaje de acierto del 97.2% para una frecuencia de 157Hz y de 98.9% para una frecuencia de 90Hz para el contraste CTFF y un porcentaje de 96.5% para una frecuencia de 157Hz y de 96.4% para una frecuencia de 90Hz.
- ❖ Se puede observar que en la detección de profundidades se presenta un error en la clasificación para los dos contrastes, que tiende a ubicarse en el contorno de los defectos; lo anterior permite inferir que el porcentaje de error se ve favorecido por la dispersión lateral del calor que se presenta alrededor de los defectos.

- ❖ Se observa que la validación con las dos láminas usadas en la metodología implementada por (Benítez, 2008), es más robusta con la técnica de entropía cruzada. Al hacer uso de una red neuronal usando la información de contraste proveniente de la técnica CAD-m, se obtuvo una mejoría significativa frente a los resultados obtenidos inicialmente por Benítez; sin embargo, este contraste es muy sensible y requiere de una metodología que permita escoger la mejor topología, pues de ésta depende tener un resultado aceptable.
- ❖ Se concluyó que el contraste CTFF es una técnica que permite clasificar los defectos sin tener que seleccionar un área sana, ni depender de la definición de parámetros intrínsecos del material, proporcionando una solución a las limitaciones que se han presentado en estudios anteriores. Aunque (Benítez, 2008) había llegado al mismo resultado con CAD-m, se observó que el contraste mediante filtrado de fondo es menos sensible, presentando una pequeña desviación de los resultados para el cambio de topologías manteniendo siempre un error aceptable.
- ❖ Finalmente, se realizó una observación para los resultados entre las dos frecuencias, encontrando que para CTFF los resultados mejoran al disminuir la frecuencia, mientras que para CAD-m ocurre lo contrario, lo cual se supone sucede porque no hay una compensación del calentamiento de fondo uniforme, tal como se observó en las Figura 4.5 y 4.6.

5.2 Trabajos Futuros

Los resultados obtenidos en este trabajo demuestran que la clasificación de los defectos está ligada a las técnicas de contraste térmico y al algoritmo de entrenamiento, el cual debe ser determinado a través de la implementación de la metodología propuesta en el capítulo 3 sobre otras técnicas, tales como las presentadas en (Restrepo, 2013).

Para definir de manera general que el contraste CTFF es superior a CAD-m con el algoritmo de entropía cruzada para la detección de profundidades de defectos, se considera que se debe realizar el estudio con otros materiales, al menos dentro de la categoría de materiales compuestos.

A pesar de que se presentan buenos resultados para la detección de defectos con los perfiles térmicos que contienen 30 características, es posible realizar una reducción de características determinando las más relevantes para disminuir la carga computacional que sería un beneficio desde el punto de vista de la complejidad, el uso de recursos y los tiempos de procesamiento. Una alternativa para dicha reducción radica en la medición de características globales de cada perfil.

6. Referencias

- A, B., D, M., J, B., & A, D. (2005). Reconstitution of a non uniform interface thermal resistance by inverse heat conduction application to infrared thermography testing. *Laboratoire de vision, et systemes numeriques*, 6, 79-123.
- AG, T., & Auer, D. (3 de Octubre de 2012). *Termografía, guía del bolsillo [online]*. Recuperado el 25 de Enero de 2016, de https://www.testo.com.ar/media/local_media/Gua_practica_termografia_ES.pdf
- Benítez, H. (2008). *Contribución a la Caracterización de Defectos en Termografía Infrarroja mediante Máquinas de Aprendizaje*. Cali: Universidad del Valle, Facultad de Ingeniería.
- Benitez, H., Ibarra-Castanedo, C., Bendada, A., Maldague, X., Loaiza, H., & Caicedo, E. (2007). *Nuevo contraste térmico para el ensayo termográfico no destructivo de materiales*. Cali: Universidad del valle-Escuela de Ingeniera Eléctrica y electrónica-PSI.
- Benítez, H., Loaiza, H., & Caicedo, E. (2011). *Termografía Activa Pulsada en Inspección de Materiales. Técnicas Avanzadas de Procesado*. Cali: Colección de Ciencias Físicas, Exactas y Naturales. 1ª edición.
- Boras, I., & Svaic, S. (2003). Possibilities of determination and caracterizaton of subsurface defects in material by means of thermography and 3d numerical model. *International Symposium Non-Destructive Testing in Civil Engineering 2003*. Berlin, Germany.
- Caicedo, E., & Sotelo, J. A. (2009). *Una aproximación práctica a las redes neuronales artificiales*. Cali: Programa Editorial Universidad del Valle.
- Darabi, A. (2000). *Detection and Estimation of Defect Depth in Infrared Thermography Using Artificial Neural Networks and Fuzzy Logic*. Quebec: Faculté des Sciencies et de Génie.

- Heriansyah, R., & Abu, B. (2007). Defect Depth Estimation in Passive Thermography using Neural Network Paradigm. *6th WSEAS International Conference on CIRCUITS, SYSTEMS, ELECTRONICS, CONTROL & SIGNAL PROCESSING*. Cairo, Egypt.
- Hervas, C., Gutiérrez, P., Carbonero, M., & Fernández, J. (2009). Ensamblajes de redes neuronales construidos mediante algoritmos híbridos multiobjetivo para optimizar la precisión y la sensibilidad. *VI Congreso Español sobre Metaheurísticas and Algoritmos Evolutivos y Bioinspirados (MAEB09)*, (págs. 309-316). España.
- Idurre, O., & Borja, G. (18 de Agosto de 2005). *Termografía infrarroja como ensayo no destructivo: detección de defectos en componentes aeroespaciales*. Recuperado el 28 de junio de 2016, de <http://www.interempresas.net/MetalMecanica/Articulos/11149-Termografia-infrarroja-ensayo-no-destructivo-deteccion-defectos-componentes-aeroespaciales.html>
- Ingenieros. (2008). *Paradise*. Recuperado el 25 de Junio de 2016, de <http://www.ingenieurparadies.de/en/ipar/18021>
- Julio, R. (2011 de Mayo de 2008). *Diagrama de Cajas*. Obtenido de Estadística: <http://jaramose.blogspot.com.co/2008/05/diagrama-de-cajas-o-box-plot-qu-es-y-qu.html?m=1>
- Krapez, J. (1994). *Early detection of thermal Contrasts in Pulsed Infrared Thermography*. France: L3C Laboratory, ONERA.
- Maldague, X. (2001). *Theory and Practice of Infrared Technology for Nondestructive Testing*. New York: Wiley Interscience.
- Montes, C. M. (2009). *"Website my works"*. Recuperado el 24 de Octubre de 2016, de <http://www.wae.ciemat.es/~cardenas/docs/lessons/sobreaajuste.pdf>

- Montes, C. M. (10 de Octubre de 2014). *"Website my works"*. Obtenido de http://www.wae.ciemat.es/~cardenas/curso_MD/precisionyerrores.pdf
- Obbadi, A., & Belattar, S. (2-4 de Aug. de 2005). Characterization of delamination by a thermal method of non destructive testing. *Proc. Vth International Workshop, Advances in Signal Processing for Non Destructive Evaluation of Materials*, (págs. 203-208). Québec, Canada.
- Peña Gutiérrez, P. A. (2009). *Nuevos modelos de redes neuronales evolutivas y regresión logística generalizada utilizando funciones de base. Aplicaciones*. Granada.
- Restrepo, A. (2013). *Contribución a la solución del problema de detección y caracterización de defectos en termografía activa mediante procesamiento espacio-temporal de secuencias de imágenes infrarrojas*. Cali: Universidad del Valle- Facultad de Ingeniería.
- Socha-Garzon, D., & Ortiz, G. (2005). *Aplicación de redes neuronales MLP a la predicción de un paso en series de tiempo*. Bogota: Fundación universitaria Konrad Lorenz, facultad de Ingeniería de sistemas.
- Stupenengo, F. (2011). Materiales y Materias primas. En *Guia Didáctica - Materiales compuestos* (págs. 1-27). Argentina: Ministerio de Educacion .
- Valdovinos, R. M. (2006). *Tecnicas de submuestreo, toma de decisiones y analisis de diversidad en aprendizaje supervisado con sistemas multiples de clasificación* . España: Universidad Jaume-Departamento de lenguajes y sistemas informaticos .
- Vavilov, V. (2004). Evaluating the efficiency of data processing algorithms in transient thermal NDT. *Thermosense XXVI* , (pág. 12). Orlando-United States.